

## A Comprehensive Analysis of the Triple-Hybrid Metamodel of MLP-PSO-ARIMA for Forecasting the FSDS Index: A Case Study of Khuzestan Province

M. Ansari Ghojghar<sup>1\*</sup>

### Abstract

This study aims to evaluate the performance of the triple-hybrid metamodel of MLP-PSO-ARIMA in forecasting the frequency of dust storm days (FSDS) index across seven selected stations in Khuzestan Province during a 50-year statistical period (1970–2019). The results of the proposed triple-hybrid metamodel was compared against the standalone MLP and ARIMA models, as well as the hybrid models of MLP-PSO, ARIMA-PSO, and MLP-ARIMA, using performance metrics including R, RMSE, MAE, and NS. All the tested models demonstrated their highest accuracy during the first and second seasonal combinations. Accordingly, it was concluded that utilizing data from one or two preceding seasons yield more accurate predictions of the FSDS index for subsequent seasons in Khuzestan Province, whereas incorporating data from the third and fourth seasons does not enhance forecasting performance. Moreover, the multilayer perceptron (MLP) neural network outperformed the Box-Jenkins ARIMA model in predicting dust storm events in the region. While combining the MLP and ARIMA models improved the accuracy compared to their standalone counterparts, the improvement was not statistically significant. In contrast, the proposed triple-hybrid metamodel exhibited a statistically significant enhancement in accuracy over the dual-hybrid models.

**Keywords:** Dust Storm, Optimization Algorithm, Triple-Hybrid, Artificial Neural Network, Box-Jenkins.

Received: December 15, 2024

Accepted: April 23, 2025

## بررسی فرامدل هیبریدی سه‌گانه MLP- PSO- ARIMA به‌منظور پیش‌بینی شاخص FSDS (مطالعه موردی: استان خوزستان)

محمد انصاری قوجقار<sup>۱\*</sup>

### چکیده

پژوهش حاضر با هدف بررسی عملکرد فرامدل هیبریدی سه‌گانه ماشین- کاتالیزور- جنکینز MLP-PSO-ARIMA در پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار، در هفت ایستگاه منتخب در استان خوزستان در طول دوره آماری ۵۰ سال (۱۹۷۰-۲۰۱۹) و با استفاده از داده‌های دید افقی و کدهای سازمان جهانی هواشناسی انجام شده است. نتایج حاصل از فرامدل هیبریدی سه‌گانه فوق با استفاده از شاخص‌های R، RMSE، MAE، NS و با مدل‌های انفرادی MLP و ARIMA و همچنین فرامدل‌های هیبریدی MLP-PSO، ARIMA-PSO، MLP-ARIMA و مورد مقایسه قرار گرفته است. تمامی مدل‌های مذکور بیشترین عملکرد خود را در ترکیب‌های فصلی اول و دوم نمایش دادند. لذا می‌توان نتیجه گرفت که استفاده از یک و یا دو فصل پیشین به‌منظور پیش‌بینی شاخص FSDS در فصل‌های آتی در استان خوزستان نتایج بهتر و دقیق‌تری به‌همراه دارد و بکارگیری فصول سوم و چهارم، سبب بهبود نتیجه پیش‌بینی نخواهد شد. از طرف دیگر، دقت مدل شبکه عصبی پرسپترون چندلایه از مدل باکس- جنکینز ARIMA به‌منظور پیش‌بینی گرد و غبار استان خوزستان بیش‌تر شده است. همچنین، ترکیب مدل MLP با مدل ARIMA سبب افزایش دقت نسبت به مدل‌های انفرادی MLP و ARIMA شد ولی رشد دقت آن آنچنان معنی‌دار نبود. از طرف دیگر، مدل هیبریدی سه‌گانه سبب افزایش رشد معنی‌دار دقت نسبت به مدل هیبریدی دوگانه فوق شده است.

**کلمات کلیدی:** طوفان گرد و غبار، الگوریتم بهینه‌سازی، هیبرید سه‌گانه، شبکه عصبی مصنوعی، باکس-جنکینز.

تاریخ دریافت مقاله: ۱۴۰۳/۹/۲۵

تاریخ پذیرش مقاله: ۱۴۰۴/۲/۳

1- Assistant Professor, Department of Rehabilitation of Arid and Mountainous Regions Engineering, Faculty of Natural Resources, University of Tehran, Karaj, Iran. Email: [Ansari.ghojghar@ut.ac.ir](mailto:Ansari.ghojghar@ut.ac.ir)

\*- Corresponding Author

Doi: [10.22034/iwr.2025.494142.2812](https://doi.org/10.22034/iwr.2025.494142.2812)

۱- استادیار، گروه مهندسی احیاء مناطق خشک و کوهستانی، دانشکده منابع طبیعی، دانشگاه تهران، کرج، ایران.

\*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۴ امکان‌پذیر است.

## ۱- مقدمه

پیشنهاد شده است (Lee et al., 2017). در قسمت جنوب غربی ایران نیز، مراتع تخریب و رها شده، زمین‌های کشاورزی بایر، زمین‌های عاری از پوشش و همچنین تالاب‌های خشک‌شده (Heydarian et al., 2017)، تغییر اقلیم و خشک‌سالی (Dargahian et al., 2022)، عدم نظارت و مدیریت صحیح بر بهره‌برداری از منابع آبی و بسیاری موارد دیگر از جمله موارد مؤثر بر رخداد و شکل‌گیری طوفان‌های گرد و غبار هستند (Dargahian et al., 2024). در وقوع این طوفان‌ها، دو جزء و عنصر اصلی تأثیرگذارند: یک، وجود حجم وسیعی از ذرات ریزدانه، و دو، وجود الگوهای خاص آب و هوایی (Dargahian et al., 2019). برای ریزمقیاس‌نمایی چنین پدیده‌های آب و هوایی، از روش‌های آماری و دینامیکی استفاده می‌شود که در این بین، از مدل‌های دینامیکی بسیاری به‌منظور مطالعه گرد و غبار استفاده می‌شود (Hamidianpour et al., 2022). یکی از روش‌های کاربردی و مناسب جهت شبیه‌سازی طوفان‌های گرد و غبار و مطالعه آن‌ها، تحلیل عددی این طوفان‌ها است. طوفان گرد و غبار در واقع انتقال حجم وسیعی از ذرات گرد و غبار به‌وسیله باد است که عمدتاً کاهش قابل توجهی را در میزان دید افقی ایجاد می‌کند (Omidvar et al., 2013). فاصله افقی به‌منظور شناسایی انواع مختلف پدیده گرد و غبار در جدول ۱ نمایش داده شده است.

طوفان‌های گرد و غبار یکی از مخاطره‌های طبیعی رایج و گسترده در مناطق خشک و نیمه‌خشک هستند (Middelton, 2017)، علی‌الخصوص مناطقی که دارای خشک‌سالی‌های شدید و طولانی‌مدت، بارندگی اندک و رطوبت کم و خاک سست حساس به فرسایش به همراه پوشش گیاهی اندک هستند (Goudie, 2018). خشک‌سالی پدیده‌ای طبیعی است که رخداد آن با خطرانی مانند ایجاد اثرات معنی‌دار بر نظم فعالیت‌های انسان، کاهش توان تولید محصولات زراعی و کمبود آب همراه است (Yousefi Mabarhan et al., 2024). این پدیده با شدت و میزان بارندگی و همچنین مقیاس زمانی میان دو فصل مرطوب، ارتباطی تنگاتنگ دارد (Bong et al., 2020). وقوع این پدیده در سالیان اخیر سبب درگیری بخش‌های وسیعی از ایران با طوفان‌های گرد و غبار شده است (Yousefi Mabarhan et al., 2024)؛ به‌طوری‌که این طوفان‌ها در مناطق شرق و غرب کشور نسبت به سایر مناطق از شدت و وسعت بیش‌تری برخوردار هستند و جنوب شرق نیز به‌عنوان یکی از اساسی‌ترین منابع گرد و غبار در ایران و جهان شناخته شده است (Miri et al., 2009; Rashki et al., 2013a; Rashki et al., 2013b; Fiedler et al., 2014; Miri, 2020). در این بین، استفاده از شاخص‌های خشک‌سالی مانند شاخص بارش استاندارد شده (SPI) به‌منظور ارزیابی و تحلیل اثرات تغییر اقلیم بر روند خشک‌سالی‌های کوتاه‌مدت و میان‌مدت،

**Table 1- Dust classification by visibility range and intensity (Shahsavani et al., 2010)**

**جدول ۱- تقسیم‌بندی گرد و غبار بر اساس قابلیت مشاهده و شدت آن (Shahsavani et al., 2010)**

Horizontal Visibility Range	Description	Dust Event Type
Less than 1000 meters	The most severe type of dust occurrence that completely pollutes the air. In very severe cases, horizontal visibility can drop to nearly zero.	Dust Storm
1000 to 10,000 meters	Dust with moderate intensity occurs- the height of dust- and sand-carrying winds is considerable.	Blowing Dust
Less than 10,000 meters	The lowest intensity of occurrence.	Suspended Dust

است (Middelton, 1986). با توجه به قرارگیری ایران در مسیر وزش باد تعدادی از مهم‌ترین و وسیع‌ترین کانون‌های مولد گرد و غبار مانند دشت ابرفتی جلگه و فرات، صحرای زبیر عراق، دشت‌های خشک‌شده الجزیره و صحرای سوریه (یکی از مهم‌ترین و اصلی‌ترین تولیدکننده گرد و غبار در عراق)، به‌ترتیب جنوب شرق، جنوب و نواحی مرکزی، مناطق غربی، شرقی و مرکزی و در نهایت مناطق شمالی ایران تحت تأثیر آثار مخرب ناشی از وقوع این بحران‌ها قرار گرفته است (Baghbanan et al., 2020). گرد و غبار بر اساس شدت و تأثیر آن بر کاهش دید افقی به سه دسته اصلی تقسیم می‌شود: طوفان گرد و غبار، گرد و غبار وزشی و گرد و غبار معلق. طوفان‌های گرد و غبار

طوفان‌های گرد و غبار که عمدتاً در نواحی خشک و نیمه‌خشک دنیا به‌وقوع می‌پیوندند، موجبات فرسایش خاک در ابعاد گسترده را فراهم آورده و بدین ترتیب بر کیفیت هوا نیز تأثیرگذار هستند (Borzou et al., 2021). در حال حاضر، عمده‌ترین مناطق وقوع گرد و غبار را می‌توان نواحی با میزان بارش کم‌تر از ۲۵۰ میلی‌متر دانست (Shao, 2008) که در این بین، منطقه خاورمیانه با وجود اقلیم گرم و خشک خود، یکی از مناطق مستعد رخداد این پدیده مخرب به‌ویژه در دوره‌های گرم سال است (Hamidi et al., 2014). در این بین، بیش‌ترین میزان فراوانی طوفان‌های گرد و غبار، در محل برخورد مرزهای ایران، افغانستان و پاکستان، سیستان و شمال غربی بلوچستان

ایالات متحده، بین دهه‌های ۱۹۹۰ و ۲۰۰۰، وقوع طوفان‌های گردوغبار به دلیل گرم شدن اقیانوس آرام ۲۴۰ درصد افزایش یافته است (Tong et al., 2017). براساس بررسی‌های سازمان ملل متحد، این طوفان‌ها پیامدهایی مانند بیابان‌زایی، تخریب زمین، کاهش تنوع زیستی، افت بازدهی کشاورزی، کاهش دید و آسیب به سلامت انسان را به همراه دارند (UN, 2017). مجمع عمومی سازمان ملل نیز با تأکید بر اثرات اقتصادی این پدیده، آن را یکی از چالش‌های اساسی برای رفاه انسان‌ها معرفی کرده است؛ زیرا تأثیرات منفی زیادی بر زندگی و معیشت مردم دارد (UN, 2018). طوفان‌های گردوغبار، که گاهی اوقات به آن‌ها طوفان‌های شنی یا رویدادهای گردوخاک گفته می‌شود، عمدتاً به دلیل تفاوت‌های شدید فشار هوا در سیستم‌های طوفانی به وجود می‌آیند. این اختلاف فشار موجب افزایش سرعت باد در یک منطقه خاص شده و در نتیجه مقدار زیادی شن و گردوغبار از زمین‌های خشک به جو منتقل می‌شود (Tositti et al., 2022). طوفان‌های گردوغبار معمولاً به‌طور ناگهانی شکل می‌گیرند و معمولاً بیشتر از یک روز دوام نمی‌آورند، و گاهی فقط چند ساعت طول می‌کشند. از جمله تأثیرات منفی طوفان‌های گردوغبار بر سلامت انسان را می‌توان به بستری شدن در بیمارستان به دلیل مشکلات تنفسی، اختلالات قلبی-ریوی، مرگ زود هنگام، مشکلات پوستی، مننژیت و تب دره اشاره کرد (Reed and Nugent, 2018; Khaniabadi et al., 2017; Liu et al., 2017; Crooks et al., 2004; Chen et al., 2016). در حوزه اقتصاد، مطالعات پیشین تأثیرات این طوفان‌ها را بر مرگ‌ومیر نوزادان و نتایج تولد (Jones, 2020; Adhvaryu et al., 2019; Currie and Schwandt, 2016)، مرگ‌ومیر ناشی از مشکلات تنفسی و قلبی-عروقی (Jia and Ku, 2019) و غیره بررسی کرده‌اند. طوفان‌های گردوغبار معمولاً با افزایش سطح ذرات معلق همراه هستند که آلودگی هوا را تشدید کرده و افراد را در معرض خطرات بیشتری قرار می‌دهند. پژوهش‌ها ارتباط مستقیمی بین آلودگی هوا و کاهش سطح رضایت از زندگی<sup>۳</sup> را نشان داده‌اند (Levinson, 2012).

بدین ترتیب و با توجه به افزایش فراوانی طوفان‌های گرد و غبار در استان خوزستان در سال‌های اخیر، شناسایی، پایش و پیش‌بینی روند گسترش و تکامل آن امری لازم است و تحقیقات بسیاری نیز در این باره انجام شده است که در ادامه به برخی از آن‌ها اشاره شده است. Ebrahimi Kousfi et al. (2021) در مطالعه خود به بررسی دقت، عدم قطعیت و تفسیرپذیری سیستم استنتاج عصبی- فازی تطبیقی<sup>۴</sup> (ANFIS) به‌منظور پیش‌بینی غلظت گرد و غبار در مناطق نیمه خشک پرداختند. علاوه بر این، از یک ابزار تفسیر مدل بی‌وابسته<sup>۵</sup> برای قابل تفسیر کردن مدل ANFIS استفاده شد. همچنین، برای افزایش دقت پیش‌بینی مدل ANFIS، از الگوریتم بهینه‌سازی خفاش<sup>۶</sup> (BAT)

به‌عنوان شدیدترین نوع این پدیده، با غلظت بالای ذرات معلق، آلودگی گسترده‌ای در جو ایجاد می‌کنند و دید افقی را به کمتر از ۱۰۰۰ متر کاهش می‌دهند. در موارد بسیار شدید، شعاع دید افقی تقریباً به صفر می‌رسد و شرایطی خطرناک و محدودکننده برای فعالیت‌های انسانی به وجود می‌آید. گرد و غبار وزشی، که در دسته متوسط شدت قرار می‌گیرد، ناشی از وزش بادهایی است که حجم مشخصی از ذرات گرد و شن را به ارتفاعات بالا منتقل می‌کنند. این پدیده معمولاً دید افقی را در محدوده ۱۰۰۰ تا ۱۰۰۰۰ متر کاهش می‌دهد و تأثیر آن بر مناطق گسترده‌ای قابل مشاهده است. گرد و غبار معلق، خفیف‌ترین نوع این پدیده، شامل ذرات پراکنده‌ای است که در جو معلق باقی می‌مانند و دید افقی را به کمتر از ۱۰۰۰۰ متر محدود می‌کنند. این طبقه‌بندی معیاری برای تفکیک انواع گرد و غبار و ارزیابی شدت آن‌ها در شرایط مختلف اقلیمی و محیطی محسوب می‌شود (Shahsavani et al., 2012). با توجه به بررسی قدرت دید افقی و مشخصات سطح‌زمین، شرق، جنوب شرق و مرکز ایران از جمله مناطق با بیش‌ترین پتانسیل به‌منظور تبدیل به کانون‌های ایجادکننده گرد و غبار هستند (Borzou et al., 2021; Shao et al., 2008). چرخه طوفان گرد و غبار شامل انتشار، حمل ذرات، فرآیندهای رسوبگذاری و در نهایت تثبیت ذرات رسوبی به توان و میزان انرژی سطح‌زمین به‌ویژه در روزهای قبل از رخداد این طوفان بستگی دارد به‌طوری‌که در این روزها گرمای بیش‌تری به اتمسفر وارد شده است شروع طوفان‌های گرد و غبار با کاهش در دمای هوا و میان‌رطوبت موجود در جو همراه است (Borzou et al., 2021). در مناطق خشک و نیمه‌خشک، ضعف پوشش گیاهی در حفاظت از خاک، تخریب سطح خاک به دلیل مدیریت نادرست، و اثرات قابل‌توجه دما بر پایداری خاک، بستر مناسبی برای وقوع مکرر طوفان‌های گردوغبار<sup>۲</sup> (SDS) ایجاد کرده‌اند. این طوفان‌ها که به دلیل وزش بادهای شدید شکل می‌گیرند، مقادیر زیادی گردوغبار را از سطح بیابان‌ها به هوا منتقل کرده و دید افقی را به کمتر از یک کیلومتر کاهش می‌دهند (Deindee et al., 2024). در سال‌های اخیر، نه‌تنها فراوانی زمانی این طوفان‌ها افزایش یافته، بلکه گستره جغرافیایی آن‌ها نیز گسترش چشمگیری داشته است (Samadi et al., 2014). اثرات این پدیده فراتر از کاهش دید و اختلال در حمل‌ونقل بوده و پیامدهای جدی بر کیفیت زندگی، شرایط ریزاقلیمی، اکوسیستم‌ها، زیرساخت‌های ارتباطی، و بروز بحران‌های زیست‌محیطی و اجتماعی-اکولوژیکی در منطقه مطالعه و خاورمیانه داشته است (Mohammed et al., 2018).

طوفان‌های گردوغبار همچنان یکی از عوامل مهم تأثیرگذار بر زندگی انسان‌ها هستند. تغییرات آب‌وهوایی، خشکسالی‌های طولانی‌مدت و تغییرات در شیوه‌های استفاده از زمین موجب افزایش فراوانی این طوفان‌ها در سراسر جهان شده‌اند (UNEP, 2016). برای مثال، در

غلظت آلاینده  $PM_{10}$  دارد. (Rahmati et al., 2020) به ترکیب مدل‌های فازی-عصبی هیبریدی برای مدل‌سازی و پیش‌بینی منابع گردوغبار پرداختند. نتایج نشان داد که مدل ترکیبی  $ANFIS-DE^{10}$  عملکرد بهتری نسبت به سایر مدل‌های ترکیبی در پیش‌بینی طوفان‌های گردوغبار دارد. این یافته‌ها نشان می‌دهد که مدل  $ANFIS-DE$  ترکیبی به‌عنوان روشی مؤثر و مقرون‌به‌صرفه برای شناسایی کارآمد مناطق منشأ گردوغبار، با مزایایی برای سلامت عمومی و محیط‌های طبیعی که با چالش‌های ناشی از گردوغبار مواجه هستند، باید مورد بررسی بیشتر قرار گیرد. (Ansari ghoghghar et al., 2022) به ارزیابی کارایی فرامدل‌های هیبریدی یادگیری ماشین و باکس جنکینز به‌منظور مدل‌سازی طوفان‌های گرد و غبار در استان خوزستان پرداختند. این پژوهش سعی بر ارائه نوعی مدل ترکیبی جدید با استفاده از فرامدل‌های هیبریدی هوش مصنوعی و همچنین فرامدل‌های هیبریدی باکس جنکینز جهت پیش‌بینی و مدل‌سازی شاخص فراوانی روزهای همراه با طوفان گرد و غبار<sup>11</sup> (FSD) داشتند. الگوریتم‌های هیبریدی پیش‌بینی که در این تحقیق به کار رفته‌اند شامل  $SARIMA$ ،  $ARIMA-NARX$ ،  $AF-SVM$ ،  $W-ANFIS$  و  $SETAR$  هستند. نتایج پیش‌بینی نشان داد که عملکرد مدل‌های هیبریدی در پیش‌بینی شاخص  $FSD$  با کاهش تعداد روزهای دارای طوفان گردوغبار ارتباط مستقیمی دارد.

طوفان‌های گردوغبار اثرات گسترده‌ای دارند که فراتر از سلامت جسمانی هستند. تحقیقات نشان داده‌اند که رویدادهای شدید آب‌وهوایی و بلایای طبیعی می‌توانند باعث ایجاد تروما شوند و نه تنها سلامت روان افراد، بلکه رفاه عمومی جامعه را نیز تحت تأثیر قرار دهند (Berry et al., 2010). حتی افرادی که به‌طور مستقیم تحت تأثیر این طوفان‌ها قرار نمی‌گیرند، ممکن است به دلیل ارتباط با دوستان و خانواده یا پیگیری اخبار و شبکه‌های اجتماعی دچار استرس شده و اثرات غیرمستقیم زیان‌باری را متحمل شوند (Ahmadiani, 2002; Cohen, 2021; Ferreira, 2021). یکی از پیامدهای مهم طوفان‌های گردوغبار کاهش شدید قدرت دید افقی است که زندگی روزمره را با اختلال مواجه می‌سازد (Jones, 2023). این کاهش دید اغلب موجب مشکلاتی مانند ترافیک سنگین، لغو پروازها، توقف فعالیت‌هایی مانند کشاورزی و ساخت‌وساز، و حتی لغو ورزش‌ها و تفریحات در فضای باز می‌شود (Al-Hemoud et al., 2017). این اختلالات می‌توانند به‌طور قابل‌توجهی بر سلامت روان و رفاه ذهنی افراد تأثیر منفی بگذارند. اغلب پژوهش‌های انجام‌شده در این حوزه، غالباً با مدل‌های انفرادی و فرامدل‌های حداکثر دوگانه صورت گرفته است. لذا در پژوهش حاضر برای اولین بار در ایران از یک فرامدل هیبریدی سه‌گانه ماشین-کاتالیزور-باکس جنکینز به‌منظور مدل‌سازی و پیش‌بینی گرد و غبار استفاده شده است. لذا این ویژگی

استفاده شد. برای پیش‌بینی ضریب توزیع<sup>۷</sup> (DC) در ماه‌های سرد و گرم در مناطق نیمه‌خشک ایران، هفت متغیر توضیحی انتخاب شدند. نتایج نشان داد که مدل  $ANFIS+BAT$  ضریب همبستگی را برای پیش‌بینی DC در ماه‌های سرد و گرم به ترتیب ۱۰٪ و ۱۶٪ نسبت به مدل  $ANFIS$  افزایش داد. علاوه بر این، تحلیل عدم قطعیت نشان داد که مدل  $ANFIS+BAT$  نسبت به مدل  $ANFIS$  برای پیش‌بینی DC در ماه‌های سرد و گرم، بازه پیش‌بینی پایین‌تری (یعنی عدم قطعیت کمتر) دارد. همچنین، یافته‌های ابزار تفسیر مدل بی‌وابسته نشان داد که دما و بیشینه سرعت باد به ترتیب بیشترین تأثیر را در پیش‌بینی DC در ماه‌های سرد و گرم دارند. (Sobhani et al., 2020) در پژوهش خود به مدل‌سازی و پیش‌بینی گرد و غبار در غرب ایران با استفاده از مدل‌های  $ANFIS$  و توابع پایه شعاعی<sup>۸</sup> (RBF) پرداختند. بر اساس نتایج پژوهش، مقایسه عملکرد دو مدل شبکه عصبی  $ANFIS$  و RBF در بهترین شرایط نشان داد که مقدار ریشه میانگین مربعات خطا برای مدل  $ANFIS$  برابر با ۱۱ و برای مدل RBF برابر با ۱۹/۵ است. بنابراین، مدل RBF دقت بالاتری در پیش‌بینی گردوغبار در سال‌های شبیه‌سازی شده نشان داد. نتایج حاصل از مدل شبکه عصبی مصنوعی RBF در پیش‌بینی گردوغبار برای سال‌های آینده در ایستگاه‌های مورد مطالعه نشان داد که در هر دو مقیاس میانگین و حداکثر فراوانی گردوغبار، ایستگاه‌های واقع در غرب و جنوب‌غربی منطقه مورد پژوهش، در سال‌های آینده بیشتر در معرض گردوغبار قرار خواهند گرفت. (Pourgholam Amiji et al., 2021) به مقایسه عملکرد مدل‌های سری‌زمانی  $SARIMA$  و  $Holt-Winters$  به‌منظور پیش‌بینی طوفان‌های گرد و غبار در استان سیستان و بلوچستان پرداختند. نتایج پژوهش نشان داد که روش  $ANFIS$  در مقایسه با سایر روش‌ها بهترین عملکرد را ارائه داد. در مجموع، مقایسه روش‌های مورد استفاده نشان داد که روش هوش مصنوعی  $ANFIS$  بهترین عملکرد و مدل‌های سری‌زمانی مدل خودرگرسیون تجمعی میانگین متحرک فصلی<sup>۹</sup> ( $SARIMA$ ) و  $Holt-Winters$  ضعیف‌ترین عملکرد را در پیش‌بینی ارائه داده‌اند. (Ansari ghoghghar et al., 2021) در پژوهش خود به ارزیابی کارایی مدل هیبریدی دوگانه  $GRU-LSTM$  برای پیش‌بینی طوفان گرد و غبار در استان خوزستان پرداختند و عملکرد این مدل هیبریدی با مدل‌های RBF و SVM مورد مقایسه قرار گرفته است. نتایج تحقیقات آنان نشان داد که در مجموع مدل هیبریدی پیشنهادی عملکرد بهتری نسبت به سایر مدل‌ها داشته و پس از آن مدل SVM در جایگاه بعدی قرار گرفته است. (Bakhshizadeh et al., 2022) به توسعه مدل  $GA-ANFIS$  به‌منظور پیش‌بینی غلظت آلاینده  $PM_{10}$  در شهر تهران پرداختند. محاسبه شاخص‌های عملکرد نشان داد که مدل ترکیبی  $GA-ANFIS$  در مقایسه با مدل  $ANFIS$  توانایی بیشتری در پیش‌بینی

عامل رجحان پژوهش حاضر نسبت به سایر پژوهش‌های انجام شده است.

## ۱-۱- بهینه‌سازی<sup>۱۲</sup>

بهینه‌سازی به معنای یافتن مقادیری برای پارامترهای یک تابع است که موجب حداقل یا حداکثر شدن مقدار آن تابع شوند. مقادیری که این شرایط را برآورده می‌کنند، راه‌حل‌های ممکن نام دارند و بهترین مقدار در میان آن‌ها به عنوان راه‌حل بهینه شناخته می‌شود. این فرآیند در حل مسائل بهینه‌سازی و کمینه‌سازی کاربرد دارد و در حوزه‌هایی مانند تخصیص منابع، زمان‌بندی و تصمیم‌گیری نقش کلیدی ایفا می‌کند. اگرچه بهینه‌سازی از اهمیت زیادی برخوردار است؛ اما همواره با چالش‌هایی همراه بوده است. روش‌های قدیمی برای حل این مسائل معمولاً نیازمند محاسبات پیچیده و زمان‌بر بودند. با این حال، ظهور الگوریتم‌های مبتنی بر هوش جمعی<sup>۱۳</sup>، به کاهش این مشکلات کمک شایانی کرده است. این الگوریتم‌ها قادرند راه‌حل‌هایی نزدیک به مقدار بهینه را بیابند و بر اساس رفتارهای جمعی طراحی شده‌اند (Shilane et al., 2008). هوش جمعی به عنوان یکی از شاخه‌های هوش مصنوعی، بر تعامل عامل‌ها با محیط و یکدیگر تمرکز دارد و از این طریق راه‌حل‌های مؤثری ارائه می‌دهد. از میان برجسته‌ترین روش‌های مبتنی بر هوش جمعی می‌توان به بهینه‌سازی کلونی مورچه‌ها<sup>۱۴</sup>، بهینه‌سازی اجتماع ذرات<sup>۱۵</sup> (PSO)، بهینه‌سازی زنبور عسل<sup>۱۶</sup> و بهینه‌سازی کرم شب‌تاب<sup>۱۷</sup> اشاره کرد که هر یک در حل مسائل پیچیده بهینه‌سازی کاربردهای قابل توجهی داشته‌اند.

### ۱-۱-۱- الگوریتم بهینه‌سازی اجتماع ذرات (PSO)

الگوریتم بهینه‌سازی ازدحام ذرات (PSO)، که در سال ۱۹۹۵ توسط کندی<sup>۱۸</sup> و ابرهارت<sup>۱۹</sup> توسعه یافت، روشی مبتنی بر جمعیت برای حل مسائل بهینه‌سازی است. ایده اصلی این الگوریتم از رفتار اجتماعی پرندگان در هنگام جستجوی غذا الهام گرفته شده است. در واقع این الگوریتم مدلی از تعامل اجتماعی بین ذرات مستقل است که با استفاده از دانش اجتماعی خود، مقدار کمینه یا بیشینه یک تابع را پیدا می‌کنند (Shafiei Chafi et al., 2021). سادگی در ساختار، بهره‌وری محاسباتی بالا و پیاده‌سازی آسان، این روش را به یکی از ابزارهای پرکاربرد در مسائل مختلف بهینه‌سازی تبدیل کرده است. در PSO، هر ذره به عنوان عضوی از جمعیت تعریف می‌شود که حجمی اندک و جرمی ناچیز دارد. این ذره با چهار بردار اصلی مشخص می‌شود: موقعیت کنونی، بهترین موقعیتی که تاکنون کشف کرده است، بهترین موقعیتی که در میان همسایگانش یافته شده، و سرعت حرکت.

به‌روزرسانی موقعیت ذرات در این الگوریتم با تکیه بر دو شاخص انجام می‌شود: بهترین موقعیتی که ذره به‌صورت فردی شناسایی کرده است و بهترین موقعیتی که توسط سایر ذرات همسایه کشف شده است. بدین ترتیب، PSO یک روش بهینه‌سازی تکراری است که در آن ابتدا جمعیتی از ذرات برای فرایند جستجو تولید می‌شود. این ذرات در فضایی چندبعدی حرکت می‌کنند و هر کدام دو پارامتر، موقعیت و سرعت، دارند که در طول فرایند و در تمامی ابعاد به‌روزرسانی می‌شوند. هر ذره موقعیت خود را بر اساس بهترین موقعیتی که تاکنون به دست آورده و بهترین موقعیتی که سایر ذرات به آن رسیده‌اند، تغییر می‌دهد (Shafiei Chafi et al., 2021). در هر تکرار، این معیارها به ذرات کمک می‌کنند تا به تدریج به سمت راه‌حل‌های بهینه حرکت کنند و با هماهنگی جمعی، جستجوی مؤثرتری داشته باشند (Kiranyaz et al., 2014). این روش تعادلی مناسب بین جستجو و بهره‌برداری برقرار می‌کند، قابلیت پردازش موازی دارد و در برابر انتخاب‌های اولیه پارامترها مقاوم است. به همین دلیل، حتی زمانی که مقادیر اولیه بهینه نباشند، این الگوریتم می‌تواند راه‌حل‌های مناسبی پیدا کند (Panicker et al., 2024).

الگوریتم بهینه‌سازی ازدحام ذرات (PSO) با اصولی ساده و کاربردی عمل می‌کند که مراحل اصلی آن به شرح زیر است (Panicker et al., 2024):

۱. **مقدمه‌سازی:** در ابتدا، جمعیتی از ذرات به‌طور تصادفی در فضای جستجو ایجاد می‌شوند. هر ذره دارای موقعیت و سرعت اولیه است و یک راه‌حل ممکن برای مسأله بهینه‌سازی را نشان می‌دهد؛

۲. **ردیابی بهترین شخصی<sup>۲۰</sup>:** هر ذره بهترین موقعیتی را که تاکنون تجربه کرده است ثبت می‌کند، که به آن بهترین شخصی یا **pbest** گفته می‌شود؛

۳. **ثبت بهترین جهانی<sup>۲۱</sup>:** الگوریتم موقعیتی را که به‌عنوان بهترین نتیجه در میان تمام ذرات تا آن لحظه شناسایی شده است، به‌عنوان بهترین جهانی (بهترین در کل) یا **gbest** ذخیره می‌کند؛

۴. **به‌روزرسانی موقعیت و سرعت:** موقعیت و سرعت هر ذره بر اساس ترکیبی از موقعیت فعلی، بهترین شخصی، و بهترین جهانی محاسبه و به‌روزرسانی می‌شود.

مزایای PSO نسبت به سایر روش‌های فراابتکاری شامل سادگی محاسباتی، کارایی زیاد، سهولت پیاده‌سازی، و پایداری عملکرد است. این الگوریتم در مقایسه با روش‌های بهینه‌سازی دیگر، توانایی همگرایی سریع در بسیاری از مسائل پیچیده بهینه‌سازی را دارد. علاوه بر این، سادگی در استفاده از معادلات ریاضی کمتر

هواشناسی هر سه ساعت یکبار و در مجموع در هشت سینوپ در طول شبانه‌روز ثبت می‌شوند. در این مشاهدات، پدیده‌های بصری آب و هوا طبق دستورالعمل سازمان جهانی هواشناسی در ۱۰۰ کد از ۰۰ تا ۹۹ تعریف شده‌اند. از مجموع این ۱۰۰ کد، به‌طور کلی ۱۱ کد، طبق جدول ۲، برای ثبت و گزارش پدیده گرد و غبار در ایستگاه‌های مختلف هواشناسی استفاده می‌شود (O'Loingsigh et al., 2014). بنابراین تعریف سازمان جهانی هواشناسی، روز همراه با طوفان‌های گرد و غبار روزی است که در آن، حداقل در یکی از هشت سینوپ، یکی از کدهای مرتبط با گرد و غبار (۰۶، ۰۷، ۰۸، ۰۹، ۳۰، ۳۱، ۳۲، ۳۳، ۳۴، ۳۵ و ۹۸) در بخش گزارش هوای حاضر اعلام شده باشد. مشروط بر این‌که، داده‌های قدرت دید افقی متناظر با کد اعلام‌شده، در کم‌تر از ۱۰۰۰ متر ثبت شده باشد (Mohammadi, 2015). لذا در این مطالعه، به‌منظور تشخیص طوفان‌های گرد و غبار، از مولفه دید افقی  $\leq 1000$  متر برای همه کدهای گرد و غبار استفاده شده است. در جدول ۱ تقسیم‌بندی گرد و غبار براساس قابلیت مشاهده و شدت آن نشان داده شده است.

و تعداد پارامترهای محدودتر از دیگر مزایای مهم آن محسوب می‌شود. این ویژگی‌ها باعث شده‌اند که PSO توجه بسیاری از پژوهشگران را به خود جلب کند و در کاربردهای مختلفی که الگوریتم‌های بهینه‌سازی سستی ممکن است موفق نباشند، مورد استفاده قرار گیرد (Shafiei Chafi et al., 2021).

## ۲- مواد و روش‌ها

### ۲-۱- محدوده مورد مطالعه

در پژوهش حاضر به بررسی فرامدل هیبریدی سه‌گانه MLP-PSO-ARIMA و مقایسه آن با مدل‌های انفرادی MLP و ARIMA و فرامدل‌های هیبریدی MLP-PSO، ARIMA- PSO، MLP-ARIMA به منظور پیش‌بینی فصلی فراوانی روزهای همراه با طوفان‌های گرد و غبار در هفت ایستگاه هواشناسی استان خوزستان (دزفول، صفی‌آباد، مسجد سلیمان، بستان، اهواز، بندر ماهشهر و آبادان) با طول دوره آماری ۵۰ سال (۱۹۷۰-۲۰۱۹) پرداخته شده است (شکل ۱). بدین منظور از داده‌های ساعتی قدرت دید افقی و کدهای سازمان جهانی هواشناسی (WMO<sup>22</sup>) استفاده شد. مشاهده‌های پدیده‌های

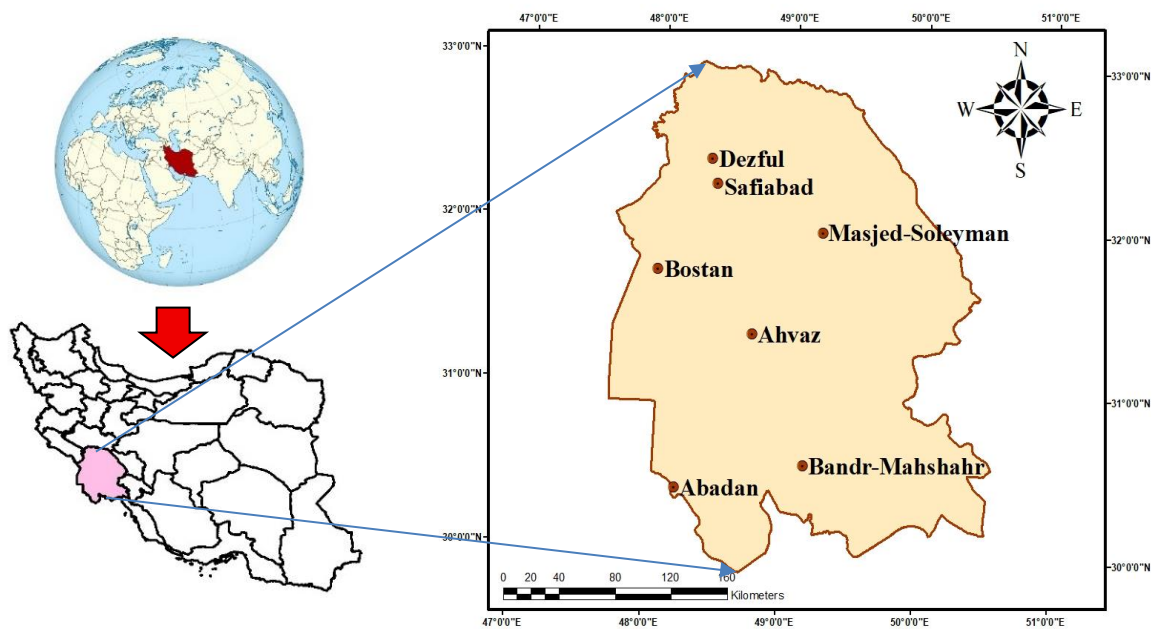


Fig. 1- Study area and monitoring stations

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه و ایستگاه‌های مورد بررسی

**Table 2- WMO codes for dust phenomena (Socha et al., 2008)**  
**جدول ۲- کدهای سازمان جهانی هواشناسی مربوط به پدیده گرد و غبار (Socha et al., 2008)**

Code	Explanation
06	Dust haze
07	Raised dust or sand
08	Well-developed dust whirls (dust devils)
09	Distant or past dust storm (distant at time of obs or past station in the past hour)
30	DECREASED slight or moderate sand or dust storm with visibility <1000 m but >200 m
31	STABLE slight or moderate sand or dust storm with visibility <1000 m but >200 m
32	BEGUN or INCREASING slight or moderate sand or dust storm with visibility <1000 m but >200 m
33	DECREASED severe dust storm with visibility <200 m
34	Stable severe dust storm with visibility <200 m
35	BEGUN or INCREASING severe dust storm with visibility <200 m
98	Thunderstorm with dust or sand storm

## ۲-۲- شبکه عصبی پرسپترون چندلایه (MLP)

که با اختصار MLP شناخته می‌شود، یکی از معروف‌ترین مدل‌های شبکه عصبی است که معمولاً به صورت پیش‌خور طراحی می‌شود (Alavi et al., 2015; Vahedi et al., 2022). MLP یک نوع شبکه پیش‌خور است که محاسبات آن به ترتیب از لایه ورودی تا لایه خروجی انجام می‌شود. در هر سطح، گره‌ها به‌طور هم‌زمان محاسبه می‌شوند و هیچ‌گونه تداخلی بین آن‌ها وجود ندارد. مقدار هر گره برابر است با مجموع وزنی مقادیر گره‌های موجود در لایه قبلی. این فرایند محاسباتی به عنوان فرایند پیش‌خور شناخته می‌شود. در این ساختار، مقدار هر گره در فرایند پیش‌خور بر اساس یک فرمول مشخص محاسبه می‌شود. این فرمول نشان‌دهنده رابطه بین گره‌ها و وزن‌ها است و نقش کلیدی در تعیین خروجی شبکه ایفا می‌کند (Zhang et al., 2018).

شبکه عصبی مصنوعی (ANN) مدلی عملیاتی است که از تعداد زیادی گره یا نرون به هم متصل تشکیل شده است. هر گره یک تابع خروجی مشخص دارد که به آن تابع فعال‌سازی گفته می‌شود. اتصالات بین گره‌ها با مقادیری وزنی نمایش داده می‌شوند که سیگنال ارتباطی را منتقل می‌کنند و به این مقادیر وزن می‌گویند. وزن در واقع نقش حافظه شبکه عصبی را ایفا می‌کند. شبکه عصبی عمیق<sup>۳۳</sup> (DNN) نوع پیشرفته‌تری از ANN است که ساختاری پیچیده‌تر و لایه‌های بیشتری دارد. یکی از ساختارهای شناخته‌شده DNN، شبکه پرسپترون چندلایه (MLP) است. این شبکه شامل چندین لایه است که به ترتیب عبارت‌اند از: لایه ورودی (اولین لایه)، لایه خروجی (آخرین لایه)، و لایه‌های مخفی که میان این دو قرار دارند. هر لایه از تعدادی نرون تشکیل شده است (شکل ۲). ویژگی مهم نرون‌ها در MLP این است که ارتباطات میان لایه‌ها به‌صورت کامل برقرار است، اما در داخل هر لایه هیچ ارتباطی وجود ندارد (Zhang, 2018). روش‌های شبکه‌های عصبی مصنوعی با هدف تقلید از توانایی یادگیری، خلاقیت و انعطاف‌پذیری مغز انسان توسعه یافته‌اند. این روش‌ها بر پایه یک سیستم آموزشی پیشرفته عمل می‌کنند (Askari-Ali-Ostad et al., 2017). ساختار کلی ANN شامل سه لایه با وظایف مشخص است: لایه ورودی که داده‌ها را به شبکه وارد می‌کند، لایه میانی که اطلاعات را پردازش می‌کند، و لایه خروجی که علاوه بر پردازش هر پارامتر ورودی، نتایج نهایی را ارائه می‌دهد (Taşpınar et al., 2014). نرون‌ها، به عنوان کوچک‌ترین واحدهای پردازشی در شبکه عصبی، نقشی کلیدی در این فرایند ایفا می‌کنند (Solegi et al., 2022). شبکه‌های عصبی پرسپترون چندلایه یکی از انواع متداول شبکه‌های عصبی هستند. این شبکه‌ها داده‌ها را از لایه ورودی به سمت لایه خروجی منتقل می‌کنند و فرایند یادگیری و پردازش به شکل پیش‌رونده انجام می‌شود (Tosan et al., 2025). پرسپترون چندلایه،

## ۲-۳- میانگین متحرک خودهمبسته یکپارچه (ARIMA<sup>24</sup>)

مدل ARIMA توسط باکس و جنکینز در سال ۱۹۷۰ معرفی شده است و به‌عنوان یک مدل تک‌متغیره جامع برای پیش‌بینی سری‌های زمانی شناخته می‌شود. این مدل به بررسی وابستگی‌های سریالی در سری زمانی می‌پردازد؛ به‌طوری‌که اجزای خودرگرسیون<sup>۲۵</sup> (AR) وابستگی متغیر وابسته را به مقادیر گذشته خود مدل‌سازی می‌کنند، در حالی که اجزای میانگین متحرک<sup>۲۶</sup> (MA) وابستگی متغیر وابسته را به خطاهای گذشته توصیف می‌کنند. این مدل عمدتاً برای سری‌های زمانی ایستا به‌کار می‌رود، جایی که میانگین، واریانس، و تابع خودهمبستگی به‌صورت تدریجی ثابت هستند (Alsuwaylimi, 2023). این مدل شامل سه مؤلفه اصلی تفاضل‌گیری، خودرگرسیون (AR)، و میانگین متحرک (MA) است (Box et al., 2015) و آن را با نماد ARIMA (p,d,q) نمایش می‌دهند. در آن p بیانگر مرتبه مؤلفه AR، d تعداد تفاضلات لازم برای تبدیل سری‌زمانی به حالت ایستا و q مرتبه مؤلفه MA است (Wang et al., 2023). برای تحلیل

در رابطه بالا،  $B$  عملگر انتقال به عقب،  $\varepsilon_t$  نویز سفید است که نشان‌دهنده یک سری زمانی با میانگین صفر و واریانس ثابت است،  $m$  دوره تناوب فصلی و یا به عبارتی طول یک چرخه کامل فصلی را نشان می‌دهد،  $\Phi_i$  و  $\theta_i$  به ترتیب پارامترهای خودرگرسیون برای بخش‌های غیرفصلی و فصلی مدل هستند و  $\theta_i$  و  $\Phi_i$  به ترتیب پارامترهای میانگین متحرک (MA) مرتبط با اجزای غیرفصلی و فصلی را نشان می‌دهند (جدول ۳). این مدل، با ترکیب اجزای فصلی و غیرفصلی، ابزاری قدرتمند برای تحلیل سری‌های زمانی با الگوهای پیچیده و دوره‌ای فراهم می‌کند (Wang et al., 2023).

سری‌های زمانی با رفتار فصلی، مدل ARIMA را می‌توان به فصلی ارتقا و گسترش داد. این مدل به صورت  $ARIMA(p, d, q)(P, D, Q)_m$  نمایش داده می‌شود که در آن  $P$  مولفه AR فصلی،  $D$  تعداد تفاضل‌های موردنیاز برای ایستایی فصلی و  $Q$  مرتبه مولفه MA فصلی است.  $m$  دوره تناوب فصلی مربوطه را نشان می‌دهد (Tsay, 2018). مدل  $ARIMA(p, d, q)(P, D, Q)_m$  برای یک سری زمانی را می‌توان با استفاده از نماد جابجایی (Backshift Notation) به صورت معادله ۱، نمایش داد:

$$\begin{aligned} & \left(1 - \sum_{i=1}^p \phi_i B^i\right) \left(1 - \sum_{i=1}^p \Phi_i B^{im}\right) (1 - B)^d (1 - B^m)^d y_t \\ & = \left(1 + \sum_{i=1}^q \theta_i B^i\right) \left(1 + \sum_{i=1}^q \Theta_i B^{im}\right) \varepsilon_t, \end{aligned} \quad (1)$$




Fig. 2- Multi-Layer Perceptron (MLP) Algorithm (Chan et al., 2023)  
 شکل ۲- الگوریتم شبکه عصبی پرسپترون تعمیم‌یافته (Chan et al., 2023)

**Table 3- Core parameter configurations for non-seasonal ARIMA models**  
**جدول ۳- ترکیب‌های پارامتر اصلی برای مدل‌های غیر فصلی ARIMA (Kontopoulou et al., 2023)**

Prediction equations	ARIMA(p,d,q)
first-order autoregressive model	ARIMA (1,0,0)
random walk	ARIMA (0,1,0)
differenced first-order autoregressive model	ARIMA (1,1,0)
simple exponential smoothing	ARIMA (0,1,1)
simple exponential smoothing with growth	ARIMA (0,1,1)
linear exponential smoothing	ARIMA (0,2,1)
linear exponential smoothing	ARIMA (0,2,2)
damped-trend linear exponential smoothing ARIMA	ARIMA (1,1,2)

#### ۴-۲- مدل‌های پیش‌بینی

FDSO باشد. در مدل شماره یک، به‌منظور پیش‌بینی FDSO برای فصل بعدی، از سری زمانی فراوانی روزهای همراه با طوفان گرد و غبار با یک گام تاخیر استفاده شده است. به بیانی دیگر، به‌منظور پیش‌بینی در زمان  $t+1$ ، از مقدار آن در زمان  $t$  استفاده شده است. در مدل شماره دو، پیش‌بینی در فصل بعدی با استفاده از مقادیر FDSO تا دو فصل قبلی آن صورت گرفته است. در مدل‌های ۳ و ۴ الی مدل ۶ نیز پیش‌بینی‌ها براساس مقادیر FDSO در سه و چهار فصل قبل انجام شده است. روابط زیر، پیش‌بینی‌های انجام‌شده در مدل‌های یک تا چهار را نمایش می‌دهد.

به‌منظور پیش‌بینی کمی فراوانی روزهای همراه با طوفان گرد و غبار، در پژوهش حاضر از شش مدل مختلف شامل دو فرامدل انفرادی ARIMA و MLP، سه فرامدل انفرادی MLP-ARIMA، PSO، MLP-ARIMA و MLP و یک فرامدل هیبریدی سه‌گانه MLP-ARIMA-PSO استفاده شده است (شکل ۳). در مرحله بعدی بهترین مدل براساس نتایج حاصل از محاسبه معیارهای نیکویی برازش انتخاب شد. در این پژوهش، متغیر مدنظر، تعداد فصل یا فصل‌های گذشته به‌منظور پیش‌بینی فصل یا فصل‌های آینده است. تعداد فصول قابل پیش‌بینی می‌تواند شامل یک، دو، سه و چهار فصل قبل‌تر از متغیر

$FDSO_{(t+1)} = f(FDSO_{(t)})$	مدل ۱
$FDSO_{(t+1)} = f(FDSO_{(t)}, FDSO_{(t-1)})$	مدل ۲
$FDSO_{(t+1)} = f(FDSO_{(t)}, FDSO_{(t-1)}, FDSO_{(t-2)})$	مدل ۳
$FDSO_{(t+1)} = f(FDSO_{(t)}, FDSO_{(t-1)}, FDSO_{(t-2)}, FDSO_{(t-3)})$	مدل ۴
$FDSO_{(t+1)} = f(FDSO_{(t)}, FDSO_{(t-1)}, FDSO_{(t-2)}, FDSO_{(t-3)}, FDSO_{(t-4)})$	مدل ۵
$FDSO_{(t+1)} = f(FDSO_{(t)}, FDSO_{(t-1)}, FDSO_{(t-2)}, FDSO_{(t-3)}, FDSO_{(t-4)})$	مدل ۶

#### ۵-۲- معیارهای ارزیابی مدل مناسب

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - f_i)^2} \quad (2)$$

$$NS = 1 - \frac{\sum_{i=1}^n (O_i - f_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - f_i| \quad (4)$$

به‌منظور ارزیابی دقت و کارایی مدل‌ها، از ضریب همبستگی  $r$  (R)، ریشه میانگین مربعات خطا  $RMSE$  (۲۸)، میانگین قدر مطلق خطا  $MAE$  (۳۰) و ضریب نش-ساتکلیف  $NS$  (۳۰) براساس معادلات ۲ تا ۵، استفاده شده است. بهترین مقدار برای این چهار نمایه، به ترتیب، یک، صفر، صفر و یک است.

در روابط بالا،  $O_i$  مقادیر مشاهده شده در زمان  $i$ ،  $f_i$  مقادیر پیش‌بینی شده در زمان  $i$ ، میانگین مقادیر مشاهده شده،  $\bar{O}$  میانگین مقادیر پیش‌بینی شده و مشاهده شده و  $n$  تعداد داده‌ها است. بر این اساس، مدلی که RMSE و MAE کم‌تری و همچنین  $R$  و  $NS$  بیش‌تری داشته باشد، کارایی و مطلوبیت بیش‌تری در حوزه مد نظر پژوهشگر دارد.

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (5)$$

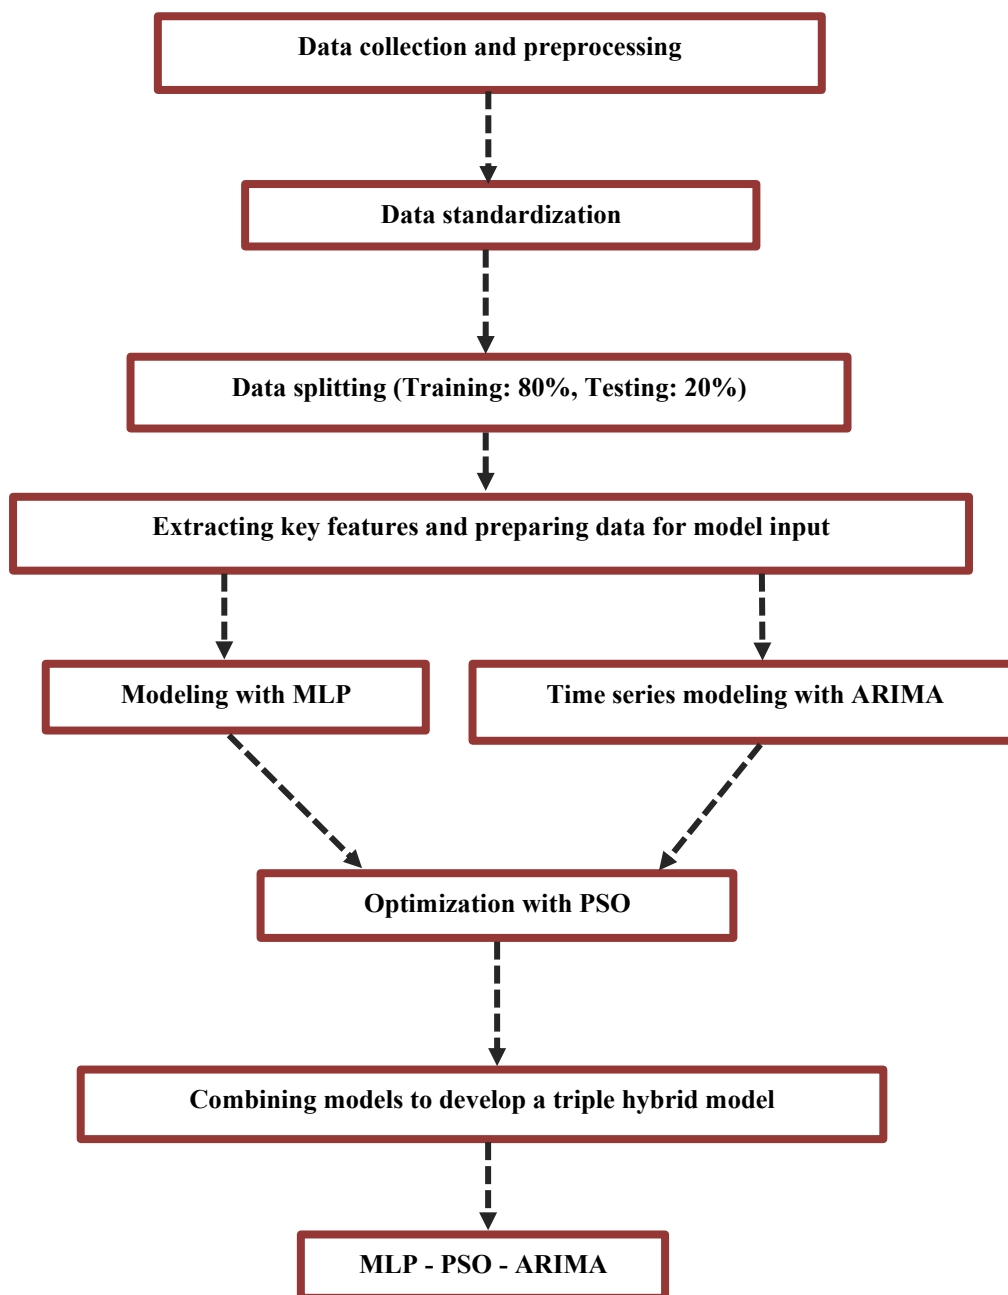


Fig. 3- Hybrid MLP-PSO-ARIMA modeling flowchart  
 شکل ۳- فلوچارت مراحل مدل‌سازی با مدل هیبریدی سه‌گانه MLP-PSO-ARIMA

### ۳- نتایج و بحث

برنامه‌نویسی R صورت گرفته است. در جدول ۳، نتایج مربوط به مدل‌سازی این شاخص نمایش داده شده است. با توجه به نتایج حاصل از مقادیر معیارهای نیکویی ارزیابی در هر هفت ایستگاه مورد بررسی، به‌طور نسبی ترکیب‌های فصلی شماره ۱ و ۲ نسبت به سایر ترکیب‌ها نتایج بهتری را ارائه دادند. در این بین نیز ترکیب شماره ۱ نسبت به ۲ عملکرد بهتری داشت. بدین ترتیب می‌توان بیان کرد که استفاده از سوابق فراوانی روزهای همراه با طوفان گرد و غبار در فصل‌های قبل، در فرآیند مدل‌سازی با این مدل سبب بهبود یافتن نتایج مدل‌سازی نمی‌شود. همان‌طور که جدول شماره ۳ نمایش داده شده‌است، استفاده از ترکیب فصلی شاخص FSDS از ترکیب فصلی ۴ به ۲، مقدار شاخص RMSE برای هر هفت ایستگاه مورد بررسی، به ترتیب از ۰/۴۸۵، ۰/۴۸۸، ۰/۴۹۰، ۰/۴۹۳، ۰/۴۹۶، ۰/۴۹۹ و ۰/۵۰۳ به ۰/۴۸۳، ۰/۴۸۶، ۰/۴۸۹، ۰/۴۹۰، ۰/۴۹۴، ۰/۴۹۷ و ۰/۴۹۹ کاهش یافته است.

برای ارزیابی کارایی و عملکرد مدل‌ها از شاخص‌های ارزیابی R، RMSE، NS و MAE استفاده شده است. مقادیر حاصل از برآورد شاخص‌های نیکویی برازش برای تعیین بهترین مدل به‌منظور برآورد فراوانی روزهای همراه با طوفان گرد و غبار در استان خوزستان و در بازه‌زمانی (۲۰۱۹-۱۹۷۰)، برای فرامدل‌های انفرادی MLP، ARIMA، مدل‌های هیبریدی MLP-PSO و ARIMA-PSO و مدل هیبریدی سه‌گانه MLP-PSO-ARIMA در جداول ۳ تا ۸ نمایش داده شده است. نتایج پیش‌بینی شاخص FSDS حاکی از عملکرد مناسب مدل هیبریدی سه‌گانه برای هر هفت ایستگاه (دزفول، صفی‌آباد، مسجد سلیمان، بستان، اهواز، بندر ماهشهر و آبادان) استان خوزستان است.

### ۳-۱- نتایج مدل‌سازی با ARIMA

پیاده‌سازی و اجرای فرامدل انفرادی میانگین متحرک خودهمبسته یکپارچه به‌منظور پیش‌بینی شاخص FSDS با استفاده از زبان

**Table 3- Statistical metrics of ARIMA model input data for FSDS prediction**  
جدول ۳- نتایج آماری داده‌های ورودی به مدل ARIMA به‌منظور پیش‌بینی شاخص FSDS

Station	Combination number	Test Dataset				Train Dataset			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
Abadan	1	0.471	0.381	0.483	0.523	0.488	0.367	0.451	0.541
	2	0.471	0.382	0.484	0.523	0.487	0.367	0.452	0.539
	3	0.470	0.382	0.484	0.523	0.487	0.368	0.452	0.539
	4	0.469	0.383	0.485	0.522	0.486	0.369	0.453	0.538
Ahvaz	1	0.469	0.384	0.486	0.521	0.486	0.369	0.453	0.537
	2	0.468	0.385	0.486	0.521	0.486	0.370	0.454	0.537
	3	0.467	0.385	0.487	0.520	0.486	0.370	0.454	0.536
	4	0.466	0.386	0.488	0.519	0.485	0.371	0.455	0.534
Bostan	1	0.466	0.387	0.489	0.518	0.484	0.372	0.456	0.534
	2	0.465	0.388	0.489	0.517	0.483	0.373	0.457	0.532
	3	0.464	0.389	0.490	0.516	0.482	0.373	0.458	0.531
	4	0.463	0.390	0.490	0.515	0.481	0.374	0.459	0.530
Masjedsoleyman	1	0.462	0.391	0.490	0.514	0.481	0.374	0.459	0.529
	2	0.461	0.392	0.491	0.513	0.481	0.375	0.461	0.528
	3	0.462	0.393	0.492	0.513	0.481	0.376	0.462	0.527
	4	0.460	0.394	0.493	0.512	0.479	0.377	0.463	0.527
Bandare-Mahshahr	1	0.460	0.395	0.494	0.512	0.478	0.378	0.464	0.526
	2	0.459	0.396	0.494	0.511	0.477	0.379	0.465	0.525
	3	0.453	0.397	0.495	0.510	0.476	0.381	0.466	0.254
	4	0.452	0.398	0.496	0.509	0.475	0.382	0.467	0.253
Safiabad	1	0.451	0.398	0.497	0.508	0.474	0.383	0.468	0.522
	2	0.451	0.398	0.498	0.507	0.473	0.384	0.469	0.521
	3	0.451	0.399	0.499	0.506	0.473	0.385	0.470	0.520
	4	0.449	0.401	0.499	0.505	0.472	0.386	0.471	0.519
Dezful	1	0.448	0.402	0.501	0.504	0.471	0.387	0.471	0.518
	2	0.447	0.402	0.501	0.503	0.469	0.388	0.472	0.517
	3	0.447	0.403	0.502	0.502	0.468	0.389	0.473	0.516
	4	0.446	0.404	0.503	0.502	0.467	0.389	0.474	0.514

### ۲-۳- نتایج مدل‌سازی با MLP

حاصل نشده است. مثلاً در ایستگاه بستان، مقدار شاخص RMSE در ترکیب شماره ۴ معادل ۰/۴۶۵ روز بوده است که با اعمال ترکیب شماره یک، شاخص مذکور کمترین مقدار یعنی ۰/۴۶۲ روز را نمایش داده است. همین روند برای سایر ایستگاه‌های مورد بررسی از جمله صفی‌آباد، مسجد سلیمان و بندرماهشهر نیز رخ داده است (شکل ۴).

جدول شماره ۴ نتایج مدل‌سازی با مدل شبکه عصبی پرسپترون چندلایه را نشان می‌دهد. در این روش نیز مانند روش قبلی، بکارگیری ترکیب‌های فصلی در یک و دو فصل پیش، نتایج مطلوب‌تر و بهتری را ارائه داده است و استفاده از فصل‌های بیش‌تر، نتایج کارآمدتری

**Table 4- Statistical metrics of MLP model input data for FDSO prediction**  
جدول ۴- نتایج آماری داده‌های ورودی به مدل MLP به منظور پیش‌بینی شاخص FDSO

Station	Combination number	Test Dataset				Train Dataset			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
Abadan	1	0.521	0.356	0.458	0.657	0.541	0.332	0.432	0.671
	2	0.521	0.356	0.458	0.656	0.541	0.334	0.432	0.671
	3	0.520	0.357	0.459	0.656	0.541	0.335	0.431	0.671
	4	0.519	0.358	0.459	0.655	0.541	0.335	0.430	0.669
Ahvaz	1	0.518	0.359	0.460	0.654	0.539	0.336	0.429	0.668
	2	0.517	0.361	0.460	0.653	0.539	0.337	0.429	0.667
	3	0.516	0.362	0.460	0.653	0.538	0.338	0.429	0.667
	4	0.516	0.363	0.461	0.652	0.538	0.339	0.428	0.665
Bostan	1	0.517	0.364	0.462	0.651	0.540	0.341	0.428	0.664
	2	0.517	0.365	0.463	0.649	0.537	0.342	0.427	0.663
	3	0.514	0.366	0.464	0.648	0.537	0.343	0.427	0.663
	4	0.514	0.367	0.465	0.647	0.536	0.344	0.426	0.662
Masjedsoleyman	1	0.514	0.368	0.466	0.646	0.534	0.345	0.425	0.661
	2	0.513	0.369	0.467	0.646	0.534	0.346	0.424	0.660
	3	0.516	0.371	0.468	0.645	0.533	0.347	0.423	0.660
	4	0.513	0.372	0.469	0.644	0.532	0.348	0.421	0.659
Bandare-Mahshahr	1	0.512	0.373	0.471	0.643	0.531	0.348	0.419	0.659
	2	0.512	0.374	0.472	0.642	0.531	0.349	0.419	0.658
	3	0.511	0.374	0.473	0.641	0.529	0.349	0.418	0.657
	4	0.511	0.375	0.474	0.641	0.529	0.351	0.417	0.657
Safiabad	1	0.511	0.376	0.475	0.639	0.528	0.352	0.417	0.656
	2	0.509	0.377	0.476	0.638	0.528	0.353	0.416	0.655
	3	0.508	0.378	0.477	0.637	0.527	0.354	0.416	0.654
	4	0.507	0.378	0.478	0.636	0.527	0.355	0.416	0.653
Dezful	1	0.507	0.379	0.479	0.635	0.526	0.356	0.414	0.652
	2	0.507	0.380	0.481	0.634	0.525	0.357	0.413	0.651
	3	0.506	0.381	0.481	0.633	0.524	0.357	0.412	0.649
	4	0.506	0.383	0.482	0.632	0.523	0.358	0.411	0.648

روزهای همراه با طوفان گرد و غبار با استفاده از مدل‌های ARIMA و ARIMA-PSO در جداول شماره ۳ و ۵، درمی‌یابیم که ترکیب مدل باکس ARIMA با کاتالیزور، کاهش دقت در پیش‌بینی را به همراه داشته است. لذا می‌توان نتیجه گرفت که هرگونه ترکیب و هیبرید مدل‌ها، نتایج بهبود یافته‌تری نسبت به حالت انفرادی را به همراه نخواهد داشت.

### ۳-۳- نتایج مدل‌سازی با ARIMA-PSO

همان‌طور که پیش‌تر نیز به آن اشاره شده است، مدل‌سازی شاخص FDSO در هفت ایستگاه در استان خوزستان با استفاده از مدل ARIMA در ترکیب‌های فصلی یک و دو، نتایج بهتری نسبت به سایر ترکیبات ارائه داده است. در روش حاضر، با ترکیب کاتالیزور PSO با مدل ARIMA، سعی بر بررسی امکان بهبود نتایج نسبت به مدل انفرادی ARIMA بود. همان‌طور که در جدول شماره ۵ نمایش داده شده است و با مقایسه نتایج آماری حاصل از پیش‌بینی شاخص فراوانی

**Table 5- Statistical metrics of ARIMA-PSO model input data for FDS D prediction**  
**جدول ۵- نتایج آماری داده‌های ورودی به مدل ARIMA-PSO به منظور پیش‌بینی شاخص FDS D**

Station	Combination number	Test Dataset				Train Dataset			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
Abadan	1	0.455	0.394	0.498	0.503	0.464	0.387	0.513	0.528
	2	0.454	0.394	0.498	0.503	0.464	0.388	0.513	0.528
	3	0.454	0.395	0.498	0.503	0.463	0.388	0.514	0.528
	4	0.454	0.396	0.499	0.502	0.462	0.388	0.515	0.527
Ahvaz	1	0.453	0.398	0.499	0.501	0.461	0.389	0.516	0.527
	2	0.452	0.397	0.500	0.501	0.460	0.391	0.517	0.526
	3	0.451	0.397	0.501	0.501	0.460	0.390	0.518	0.525
	4	0.451	0.397	0.501	0.499	0.459	0.392	0.519	0.524
Bostan	1	0.450	0.398	0.501	0.498	0.458	0.392	0.519	0.524
	2	0.449	0.399	0.501	0.498	0.457	0.393	0.520	0.523
	3	0.448	0.399	0.502	0.497	0.457	0.394	0.521	0.522
	4	0.446	0.399	0.502	0.496	0.456	0.394	0.522	0.521
Masjedsoleyman	1	0.446	0.400	0.503	0.465	0.455	0.394	0.523	0.521
	2	0.447	0.400	0.504	0.494	0.454	0.395	0.524	0.520
	3	0.445	0.401	0.502	0.493	0.453	0.395	0.525	0.519
	4	0.444	0.402	0.502	0.492	0.452	0.395	0.526	0.518
Bandare-Mahshahr	1	0.443	0.402	0.505	0.491	0.451	0.396	0.527	0.517
	2	0.442	0.403	0.506	0.490	0.451	0.397	0.528	0.516
	3	0.441	0.404	0.507	0.489	0.451	0.397	0.528	0.515
	4	0.440	0.405	0.508	0.488	0.451	0.397	0.529	0.514
Safiabad	1	0.439	0.406	0.509	0.487	0.449	0.397	0.530	0.513
	2	0.438	0.407	0.509	0.486	0.448	0.398	0.531	0.512
	3	0.437	0.408	0.510	0.485	0.447	0.399	0.532	0.511
	4	0.436	0.409	0.511	0.484	0.447	0.400	0.533	0.510
Dezful	1	0.435	0.409	0.511	0.483	0.446	0.401	0.534	0.509
	2	0.434	0.411	0.512	0.482	0.445	0.402	0.535	0.508
	3	0.433	0.412	0.513	0.481	0.445	0.403	0.536	0.508
	4	0.432	0.413	0.514	0.481	0.444	0.403	0.537	0.507

کاهش یافته است (شکل ۴). بدین ترتیب می‌توان نتیجه گرفت که ترکیب مدل انفرادی شبکه عصبی پرسپترون چندلایه با الگوریتم بهینه‌سازی ازدحام ذرات، سبب بهبود نتایج پیش‌بینی شاخص FDS D در مقایسه با مدل MLP شده است. علاوه بر این، مدل هیبریدی MLP-PSO نسبت به مدل هیبریدی ARIMA-PSO نتایج مطلوب‌تر و بهتری را نمایش داده است.

### ۳-۴- نتایج مدل‌سازی با MLP-PSO

همان‌طور که در جدول زیر نمایش داده شده است، استفاده از ترکیب‌های یک و دو در ایستگاه‌های دزفول و صفی‌آباد نتایج مشابهی را به همراه دارد. ولی با اعمال ترکیبات ۳ و ۴ در ایستگاه دزفول، دقت پیش‌بینی کاهش می‌یابد. این مورد برای ایستگاه صفی‌آباد صادق نیست و بکارگیری ترکیبات ۳ یا ۴ تغییری در نتیجه نخواهد داشت. اما در هر دوی این ایستگاه‌ها، استفاده از ترکیب‌های یک و دو نتایج مطلوب‌تری به همراه خواهد داشت. برای پنج ایستگاه دیگر نیز، روند پیش‌بینی به همین صورت بوده و استفاده از ترکیب‌های یک و دو نتایج بهتری را به نسبت سایر ترکیبات به همراه دارد. با مقایسه نتایج حاصل از مدل هیبریدی حاضر با نتایج مدل انفرادی MLP، نتایج مطلوب‌تر و دقت بالاتری حاصل شده است. برای مثال مقدار شاخص RMSE در ایستگاه آبادان از ۰/۴۵۸ روز در نتیجه مدل‌سازی با MLP به ۰/۴۰۳ روز پس از مدل‌سازی با فرامدل هیبریدی MLP-PSO

**Table 6- Statistical metrics of MLP-PSO model input data for FDS prediction**  
**جدول ۶- نتایج آماری داده‌های ورودی به مدل MLP-PSO به منظور پیش‌بینی شاخص FDS**

Station	Combination number	Test Dataset				Train Dataset			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
Abadan	1	0.637	0.312	0.403	0.721	0.652	0.298	0.387	0.743
	2	0.637	0.313	0.404	0.721	0.651	0.298	0.388	0.742
	3	0.636	0.313	0.404	0.719	0.651	0.298	0.389	0.742
	4	0.635	0.314	0.404	0.719	0.651	0.299	0.389	0.741
Ahvaz	1	0.634	0.315	0.405	0.719	0.650	0.299	0.391	0.740
	2	0.635	0.316	0.406	0.718	0.649	0.300	0.392	0.739
	3	0.633	0.316	0.407	0.718	0.648	0.300	0.393	0.738
	4	0.632	0.316	0.408	0.717	0.647	0.301	0.394	0.737
Bostan	1	0.632	0.316	0.409	0.717	0.646	0.301	0.395	0.736
	2	0.631	0.317	0.410	0.716	0.645	0.301	0.396	0.735
	3	0.630	0.317	0.411	0.715	0.644	0.302	0.397	0.734
	4	0.629	0.317	0.412	0.714	0.643	0.302	0.398	0.733
Masjedsoleyman	1	0.629	0.318	0.413	0.713	0.642	0.303	0.398	0.732
	2	0.628	0.319	0.414	0.712	0.642	0.304	0.399	0.731
	3	0.627	0.321	0.415	0.711	0.641	0.306	0.401	0.731
	4	0.627	0.322	0.416	0.709	0.639	0.305	0.402	0.731
Bandare-Mahshahr	1	0.626	0.323	0.417	0.708	0.640	0.305	0.402	0.729
	2	0.625	0.324	0.418	0.706	0.638	0.307	0.402	0.728
	3	0.624	0.325	0.418	0.705	0.640	0.308	0.402	0.727
	4	0.623	0.326	0.419	0.704	0.638	0.309	0.402	0.727
Safiabad	1	0.622	0.327	0.419	0.703	0.636	0.309	0.403	0.726
	2	0.621	0.328	0.419	0.702	0.635	0.311	0.403	0.725
	3	0.621	0.329	0.421	0.701	0.634	0.311	0.404	0.724
	4	0.620	0.331	0.421	0.701	0.633	0.312	0.405	0.723
Dezful	1	0.619	0.332	0.422	0.701	0.632	0.313	0.406	0.722
	2	0.618	0.332	0.422	0.699	0.631	0.314	0.406	0.721
	3	0.617	0.333	0.423	0.698	0.630	0.315	0.407	0.721
	4	0.616	0.334	0.424	0.697	0.629	0.316	0.408	0.721

۷- مشخص است، استفاده از مدل هیبریدی MLP-ARIMA نسبت به مدل‌های انفرادی MLP و ARIMA و مدل‌های هیبریدی MLP-PSO و ARIMA-PSO از دقت بالاتری برخوردار است.

### ۳-۵- نتایج مدل‌سازی با MLP-ARIMA

در بخش‌های پیشین به بررسی عملکرد مدل‌های انفرادی شبکه عصبی پرسپترون چندلایه و میانگین متحرک خودهمبسته یکپارچه و میزان دقت آن‌ها در پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در هفت ایستگاه سینوپتیک استان خوزستان پرداخته شده است. در این بخش، به بررسی عملکرد حاصل از ترکیب مدل‌های فوق، و با به عبارتی به ارزیابی عملکرد فرامدل هیبریدی MLP-ARIMA پرداخته شده است. همان‌طور که در جدول زیر قابل مشاهده است، هیبرید مدل‌های MLP و ARIMA سبب افزایش دقت پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در هر هفت ایستگاه موردبررسی شده است. در این بین نیز استفاده از ترکیب‌های یک و دو به منظور پیش‌بینی فصول آبی، نسبت به سایر ترکیبات نتایج دقیق‌تری را به همراه داشته است. علاوه بر این، بکارگیری ترکیب فصلی شماره یک نیز نتایج بهتری نسبت به ترکیب شماره دو داشته است. بدین ترتیب همان‌طور که از نتایج جدول شماره

**Table 7- Statistical metrics of MLP-ARIMA model input data for FDS D prediction**  
**جدول ۷- نتایج آماری داده‌های ورودی به فرامدل هیبریدی MLP-ARIMA به منظور پیش‌بینی شاخص FDS D**

Station	Combination number	Test Dataset				Train Dataset			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
Abadan	1	0.746	0.211	0.324	0.834	0.801	0.201	0.302	0.867
	2	0.746	0.211	0.325	0.833	0.801	0.201	0.303	0.866
	3	0.745	0.212	0.325	0.832	0.801	0.201	0.304	0.865
	4	0.744	0.213	0.326	0.832	0.799	0.202	0.304	0.865
Ahvaz	1	0.743	0.213	0.327	0.831	0.798	0.203	0.305	0.865
	2	0.742	0.213	0.328	0.831	0.798	0.204	0.306	0.864
	3	0.741	0.215	0.329	0.831	0.798	0.205	0.307	0.863
	4	0.740	0.214	0.330	0.830	0.797	0.206	0.308	0.862
Bostan	1	0.739	0.217	0.331	0.830	0.796	0.206	0.308	0.861
	2	0.738	0.217	0.332	0.829	0.795	0.207	0.309	0.861
	3	0.738	0.218	0.333	0.828	0.794	0.207	0.309	0.860
	4	0.738	0.219	0.334	0.827	0.793	0.208	0.311	0.859
Masjedsoleyman	1	0.737	0.221	0.335	0.827	0.792	0.209	0.312	0.858
	2	0.736	0.223	0.336	0.826	0.791	0.209	0.313	0.858
	3	0.735	0.224	0.337	0.825	0.791	0.210	0.314	0.857
	4	0.734	0.225	0.338	0.824	0.790	0.211	0.315	0.857
Bandare-Mahshahr	1	0.733	0.227	0.339	0.823	0.789	0.211	0.315	0.856
	2	0.732	0.227	0.340	0.822	0.788	0.212	0.316	0.855
	3	0.731	0.228	0.341	0.821	0.787	0.212	0.317	0.854
	4	0.730	0.229	0.342	0.820	0.786	0.213	0.318	0.853
Safiabad	1	0.729	0.231	0.343	0.820	0.786	0.213	0.319	0.852
	2	0.729	0.232	0.344	0.820	0.785	0.214	0.320	0.851
	3	0.728	0.233	0.345	0.819	0.784	0.215	0.321	0.850
	4	0.727	0.234	0.346	0.818	0.784	0.216	0.322	0.849
Dezful	1	0.726	0.235	0.346	0.817	0.783	0.217	0.323	0.849
	2	0.725	0.236	0.347	0.816	0.782	0.218	0.324	0.848
	3	0.724	0.237	0.348	0.815	0.781	0.218	0.325	0.847
	4	0.723	0.238	0.349	0.814	0.780	0.219	0.326	0.847

ایستگاه اهواز، این مقدار از ۰/۴۹۹ روز در نتیجه مدل‌سازی با مدل ARIMA-PSO به ۰/۴۸۶ روز در نتیجه مدل‌سازی با ARIMA، ۰/۴۶۰ روز در نتیجه مدل‌سازی با MLP، ۰/۴۰۵ روز در نتیجه مدل‌سازی با فرامدل هیبریدی MLP-PSO، ۰/۳۲۷ روز در نتیجه مدل‌سازی با فرامدل هیبریدی MLP-ARIMA و در نهایت به ۰/۱۵۹ روز در نتیجه مدل‌سازی با فرامدل هیبریدی سه‌گانه MLP-PSO-ARIMA کاهش یافته است (شکل ۴). بدین ترتیب می‌توان نتیجه گرفت که استفاده از فرامدل هیبرید سه‌گانه فوق، با اختلاف نتایج بهتر و دقت بالاتری را در فرآیند مدل‌سازی و پیش‌بینی شاخص FDS D در هفت ایستگاه استان خوزستان به همراه دارد.

### ۳-۶- نتایج مدل‌سازی با فرامدل هیبریدی MLP-PSO-ARIMA

در جدول شماره ۸، نتایج پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار با استفاده از فرامدل هیبرید سه‌گانه MLP-PSO-ARIMA نمایش داده شده است. این مدل از هیبرید MLP و ARIMA و الگوریتم بهینه‌سازی ازدحام ذرات تشکیل شده است. همان‌طور که از بررسی نتایج حاصل از معیارهای ارزیابی مدل در جدول ۸ در می‌یابیم، استفاده از این مدل هیبرید سه‌گانه سبب افزایش قابل ملاحظه دقت نتایج مدل‌سازی و پیش‌بینی شاخص FDS D نسبت به سایر مدل‌های انفرادی و هیبریدی بررسی شده در بخش‌های بالاتر، شده است. در این فرامدل هیبریدی نیز استفاده از ترکیب‌های فصلی یک و دو سبب بهبود فرآیند پیش‌بینی شاخص FDS D در فصل‌های آتی شده است. برای مثال با مقایسه مقادیر RMSE حاصل از پیش‌بینی شاخص فراوانی روزهای همراه با طوفان گرد و غبار در

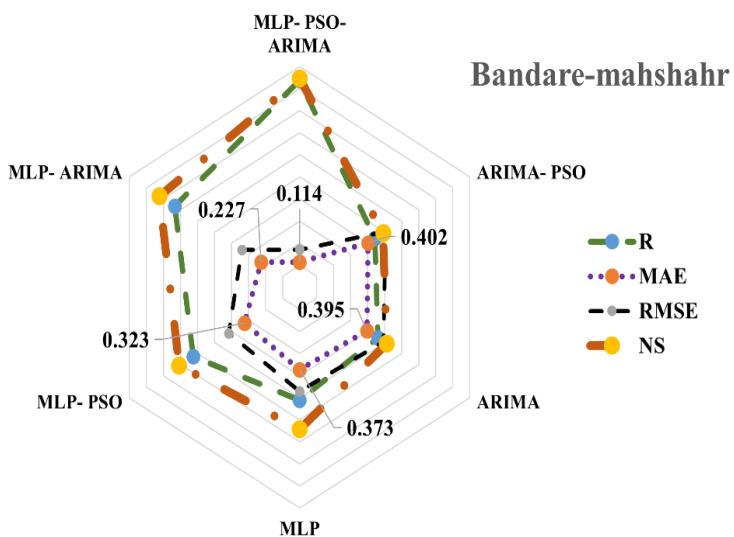

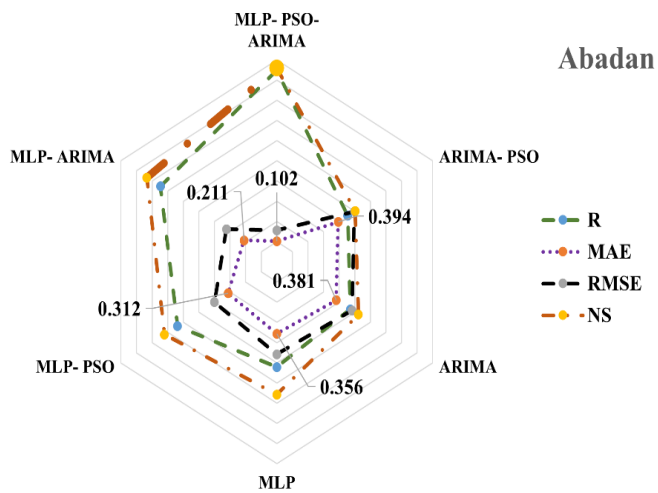
**Table 8- Statistical metrics of MLP-PSO-ARIMA model input data for FDS D prediction**  
**جدول ۸- نتایج آماری داده‌های ورودی به فرامدل هیبریدی MLP-PSO-ARIMA به منظور پیش‌بینی شاخص FDS D**

Station	Combination number	Test Dataset				Train Dataset			
		R	MAE	RMSE	NS	R	MAE	RMSE	NS
Abadan	1	0.948	0.102	0.156	0.959	0.972	0.087	0.104	0.986
	2	0.947	0.103	0.157	0.958	0.972	0.087	0.104	0.985
	3	0.947	0.104	0.158	0.958	0.971	0.088	0.105	0.984
	4	0.947	0.104	0.159	0.958	0.970	0.088	0.106	0.983
Ahvaz	1	0.946	0.104	0.159	0.957	0.970	0.089	0.107	0.982
	2	0.945	0.105	0.159	0.956	0.969	0.091	0.108	0.981
	3	0.944	0.106	0.161	0.955	0.968	0.092	0.109	0.981
	4	0.943	0.107	0.162	0.954	0.967	0.092	0.111	0.980
Bostan	1	0.942	0.108	0.163	0.953	0.967	0.093	0.112	0.980
	2	0.942	0.108	0.164	0.952	0.966	0.093	0.112	0.979
	3	0.941	0.109	0.165	0.951	0.965	0.094	0.112	0.979
	4	0.940	0.110	0.166	0.950	0.965	0.095	0.112	0.978
Masjedsoleyman	1	0.939	0.111	0.167	0.949	0.964	0.096	0.113	0.978
	2	0.938	0.112	0.168	0.948	0.963	0.096	0.114	0.976
	3	0.937	0.112	0.169	0.947	0.962	0.097	0.115	0.976
	4	0.937	0.113	0.169	0.946	0.961	0.098	0.116	0.975
Bandare-Mahshahr	1	0.936	0.114	0.170	0.946	0.960	0.099	0.116	0.974
	2	0.935	0.115	0.171	0.945	0.960	0.101	0.116	0.973
	3	0.934	0.115	0.172	0.944	0.959	0.102	0.117	0.972
	4	0.934	0.116	0.173	0.943	0.958	0.103	0.118	0.971
Safiabad	1	0.933	0.117	0.174	0.942	0.958	0.104	0.119	0.970
	2	0.932	0.117	0.175	0.942	0.957	0.105	0.121	0.969
	3	0.931	0.118	0.176	0.941	0.957	0.106	0.121	0.969
	4	0.930	0.119	0.177	0.941	0.956	0.106	0.121	0.968
Dezful	1	0.930	0.120	0.178	0.939	0.955	0.107	0.122	0.968
	2	0.929	0.121	0.179	0.938	0.954	0.108	0.123	0.967
	3	0.928	0.121	0.180	0.937	0.953	0.109	0.124	0.965
	4	0.927	0.122	0.181	0.937	0.953	0.111	0.124	0.964

x دارد. ویژگی یاد شده حاکی از راندمان بالا و کارایی بالا فرامدل هیبریدی سه‌گانه ماشین- کاتالیزور- جنکینز MLP-PSO-ARIMA در مقایسه با سایر مدل‌های انفرادی و فرامدل‌های هیبریدی بررسی شده به منظور پیش‌بینی شاخص FDS D دارد. از سوی دیگر، مقایسه میانگین مقادیر مشاهده‌شده و پیش‌بینی شده شاخص فراوانی روزهای همراه با طوفان و غبار در استان خوزستان در دوره زمانی ۵۰ ساله بر اساس آزمون t، نشانگر قبول فرض صفر یعنی برابری میانگین سری‌های زمانی مشاهده شده و پیش‌بینی شده است. لذا می‌توان نتیجه گرفت که همه مدل‌های موردبررسی، میانگین سری‌زمانی را حفظ کرده‌اند.

### ۷-۳- مقایسه عملکرد مدل‌های MLP، ARIMA، MLP-PSO، ARIMA-PSO و MLP-ARIMA با فرامدل هیبریدی سه‌گانه MLP-PSO-ARIMA

شکل شماره ۵، مقادیر مشاهده‌شده و پیش‌بینی شده شاخص فراوانی روزهای همراه با طوفان گرد و غبار را برای داده‌های آزمون ایستگاه‌های مذکور در استان خوزستان نشان می‌دهد. همان‌طور که در این شکل مشخص است، رابطه میان مقادیر مشاهده‌شده و پیش‌بینی شده در همه ایستگاه‌های استان خوزستان توسط خطی با شیب ۴۵ درجه مورد ارزیابی قرار گرفته است. مدل هیبریدی ARIMA-PSO با بیش‌ترین پراکندگی نسبت به سایر مدل‌ها، بیش‌ترین فاصله با نیم‌ساز ربع اول و سوم و کم‌ترین مطابقت و دقت را دارد. در مقابل، فرامدل هیبریدی سه‌گانه MLP-PSO-ARIMA با کم‌ترین پراکندگی و بالاترین دقت، بیش‌ترین مطابقت را با خط  $y = x$




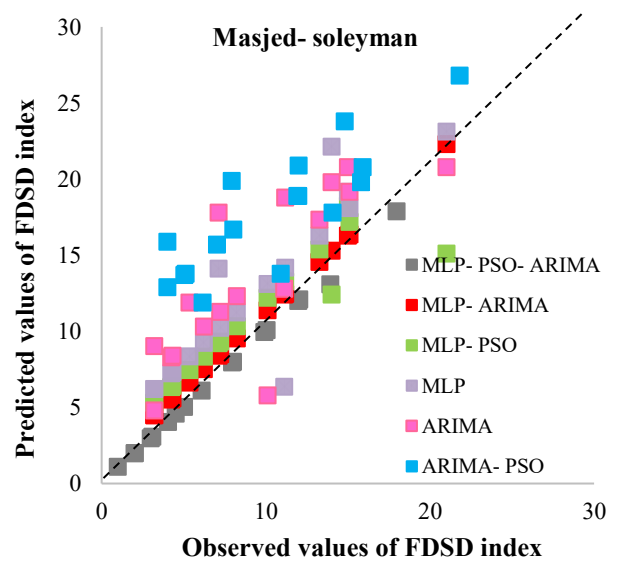

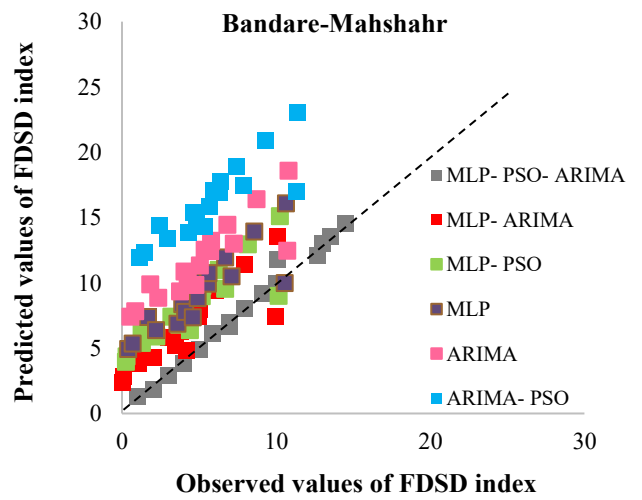
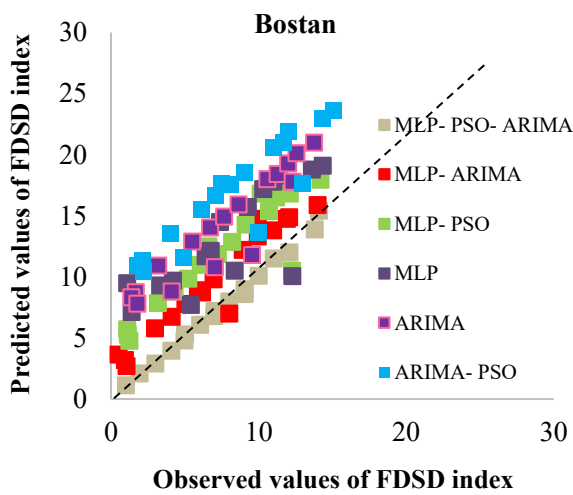

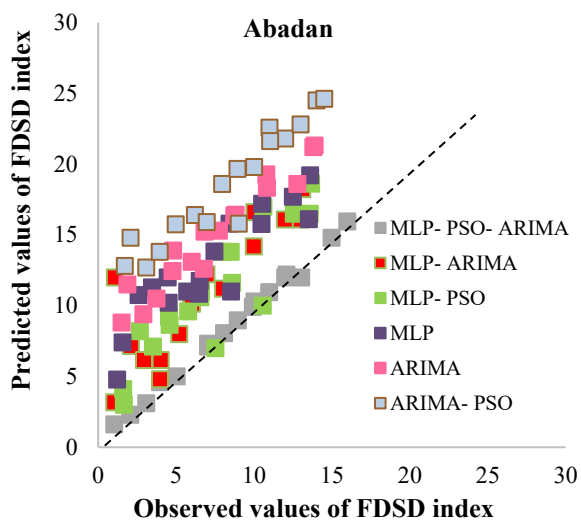


Fig. 4- Comparison of the goodness-of-fit indices for Khuzestan stations-first combination number  
 شکل ۴- مقایسه شاخص های نیکویی برازش برای ایستگاه های استان خوزستان- ترکیب فصلی شماره ۱



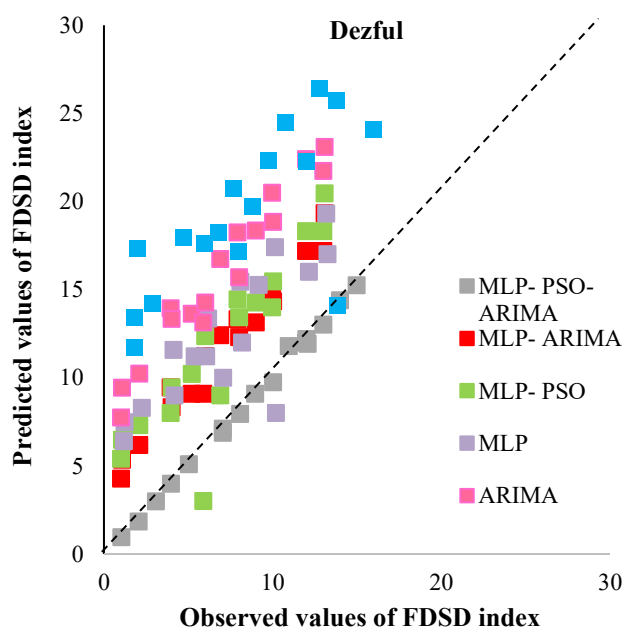


Fig. 5- Comparative analysis of observed and predicted FDS values across MLP, ARIMA, MLP-PSO, ARIMA-PSO, MLP-ARIMA models, and the triple-hybrid MLP-PSO-ARIMA metamodel

شکل ۵- مقایسه مقادیر مشاهده شده و پیش بینی شده شاخص FDS با استفاده از مدل های MLP، ARIMA، MLP-PSO، ARIMA-PSO و فرامدل هیبرید سه گانه MLP-PSO-ARIMA

Table 9- Statistical test comparing mean values of observed and predicted FDS time series  
جدول ۹- آزمون مقایسه میانگین سری زمانی مشاهداتی و پیش بینی شده شاخص FDS

Station	Observed	Average					t-statistic						
		MLP- PSO- ARIMA	MLP- ARIMA	ARIMA- PSO	MLP- PSO	ARIMA	MLP	MLP- PSO- ARIMA	MLP- ARIMA	ARIMA- PSO	MLP- PSO	ARIMA	MLP
1. Abadan	0.923	0.918	0.903	0.771	0.885	0.801	0.803	2.334	2.221	1.854	2.128	2.007	2.011
2. Ahvaz	0.909	0.902	0.891	0.748	0.872	0.796	0.802	2.321	2.127	1.702	2.113	1.956	2.008
3. Bostan	0.902	0.900	0.883	0.723	0.803	0.782	0.796	2.224	2.106	1.603	2.052	1.852	1.991
4. Masjed-soleyman	0.896	0.893	0.845	0.711	0.801	0.756	0.785	2.125	2.101	1.502	2.041	1.803	1.893
5. Bandare-Mahshahr	0.891	0.887	0.832	0.706	0.779	0.732	0.741	2.110	2.004	1.428	2.001	1.703	1.724
6. Safiabad	0.882	0.874	0.802	0.701	0.775	0.728	0.732	2.025	2.001	1.111	1.995	1.621	1.625
7. Dezful	0.875	0.871	0.801	0.699	0.734	0.702	0.709	2.007	1.998	1.004	1.956	1.541	1.620

#### ۴- نتیجه‌گیری و جمع‌بندی

ارزیابی و مقایسه عملکرد مدل‌های مذکور به کار گرفته شدند. نتایج حاصل از بررسی شاخص‌ها در مراحل آموزش و آزمایش مدل‌ها، نشان‌دهنده دقت بالاتر، عملکرد بهتر و میزان خطای کم‌تر فرامدل هیبریدی سه‌گانه، در مقایسه با ۵ مدل بررسی شده دیگر بود. نکته قابل توجه آن است که عملکرد مدل باکس ARIMA پس از هیبرید با الگوریتم بهینه‌سازی ازدحام ذرات، کاهش دقت و عملکرد مدل را در پی داشت. لذا نتیجه می‌گیریم استفاده از کاتالیزورها همیشه ضمانت‌کننده افزایش دقت و کارایی مدل نیست. بدین ترتیب مدل ARIMA-PSO کمترین دقت و عملکرد را در میان مدل‌های موردبررسی داشت. پس از آن، ARIMA با مقدار اندکی بهبود عملکرد نسبت به ARIMA-PSO، در رتبه پنجم از نظر دقت قرار می‌گیرد. برخلاف آنچه درباره مدل ARIMA بیان شد، مدل شبکه عصبی پرسپترون چندلایه پس از هیبرید با کاتالیزور PSO، نتایج بهبود یافته‌تری را ارائه می‌دهد. لذا مدل MLP انفرادی و MLP-PSO به ترتیب در جایگاه‌های چهارم و سوم از نظر دقت و کارایی در پیش‌بینی شاخص FDSO قرار می‌گیرند. ترکیب مدل‌های انفرادی MLP و ARIMA همان‌طور که در جدول ۷ نمایش داده شده است، سبب بهبود نتایج و دقت در پیش‌بینی شاخص FDSO نسبت به بکارگیری مدل‌های انفرادی به‌تنهایی شده است. لذا فرامدل هیبریدی MLP-ARIMA در جایگاه دوم از نظر دقت و حداقل خطای محاسبه در میان مدل‌های بررسی شده قرار دارد. در نهایت نیز، فرامدل هیبریدی MLP-PSO-ARIMA با حداقل مقدار RMSE و MAE در میان مدل‌های مذکور، با اختلاف بهترین عملکرد و بیش‌ترین دقت را در برآورد و پیش‌بینی شاخص FDSO در تمامی هفت ایستگاه استان خوزستان دارد.

#### پی‌نوشت‌ها

- 1- Standardized Precipitation Index
- 2- Sand and Dust Storms
- 3- Life Satisfaction
- 4- Adaptive Neuro-Fuzzy Inference System
- 5- Model-Agnostic Interpretation
- 6- Bat Algorithm
- 7- Distribution Coefficient
- 8- Radial Basis Function
- 9- Seasonal AutoRegressive Integrated Moving Average
- 10- Differential Evolution
- 11- Frequency of Dust Storm Days
- 12- Optimization
- 13- Swarm Intelligence
- 14- Ant Colony Optimization
- 15- Particle Swarm Optimization
- 16- Artificial Bee Colony Algorithm
- 17- Firefly Algorithm

طوفان‌های گردوغبار، به‌عنوان یکی از مهم‌ترین مخاطرات زیست‌محیطی در مناطق خشک و نیمه‌خشک، تحت تأثیر عواملی نظیر خشکسالی‌های شدید، بارندگی اندک، و خاک‌های حساس به فرسایش به وقوع می‌پیوندند. در ایران، این پدیده به‌ویژه در مناطق شرقی، جنوب شرقی و مرکزی کشور شدت بیشتری یافته و کانون‌های اصلی گردوغبار در این مناطق شکل گرفته‌اند. تخریب مراتع، خشک‌شدن تالاب‌ها، سوءمدیریت منابع آبی، و تغییرات اقلیمی از عوامل کلیدی تشدید این طوفان‌ها هستند که منجر به انتقال گسترده ذرات معلق به جو، کاهش دید افقی، فرسایش شدید خاک، و آلودگی گسترده هوا شده‌اند. پیامدهای طوفان‌های گردوغبار فراتر از اثرات محیطی، طیف گسترده‌ای از مسائل بهداشتی، اجتماعی و اقتصادی را شامل می‌شود. این پدیده‌ها با افزایش سطح ذرات معلق در هوا، مشکلات تنفسی، قلبی-عروقی، و حتی آسیب‌های پوستی را به‌دنبال دارند و از سوی دیگر، با ایجاد استرس و پیامدهای روانی، رفاه عمومی جامعه را تحت تأثیر قرار می‌دهند. افزون بر این، اختلال در حمل‌ونقل، کاهش بهره‌وری کشاورزی، و افت کیفیت زندگی از پیامدهای مستقیم این طوفان‌ها است. خاورمیانه، به‌ویژه مناطق ایران، افغانستان و پاکستان، به‌دلیل اقلیم گرم و خشک خود، از جمله نواحی مستعد این پدیده مخرب در سطح جهانی محسوب می‌شوند. مقابله با طوفان‌های گردوغبار مستلزم رویکردهای چندوجهی است. به‌کارگیری مدل‌های پیشرفته دینامیکی و تحلیل عددی، ابزارهای کلیدی برای شبیه‌سازی و پیش‌بینی این پدیده هستند. افزون بر آن، احیای پوشش گیاهی، بازنگری در مدیریت منابع طبیعی، و کاهش بهره‌برداری ناپایدار از اراضی می‌تواند نقش مؤثری در کاهش شدت و فراوانی این طوفان‌ها داشته باشد. تدوین سیاست‌های اقلیمی پایدار و آگاهی‌بخشی عمومی نیز از ضروریات اساسی برای کاهش اثرات این پدیده و بهبود شرایط زیست‌محیطی و اجتماعی است. بدین ترتیب و با توجه به تمامی موارد بیان‌شده، یکی از رویکردهای اساسی به‌منظور مقابله و کاهش اثرات و مشکلات ناشی از این پدیده، توسعه و استقرار سیستم‌های پیش‌بینی طوفان‌های گرد و غبار است. این سیستم‌ها با بهره‌گیری از مدل‌های پیشرفته جوی، داده‌های ماهواره‌ای، و روش‌های ریزمقیاس‌نمایی، امکان پیش‌بینی دقیق زمان، شدت، و مسیر حرکت طوفان‌های گردوغبار را فراهم می‌آورند. لذا هدف پژوهش حاضر، ارزیابی عملکرد فرامدل هیبریدی سه‌گانه MLP-PSO-ARIMA و مقایسه آن با مدل‌های MLP، ARIMA، MLP-PSO، و ARIMA-PSO و MLP-ARIMA به‌منظور پیش‌بینی فراوانی روزهای همراه با طوفان گرد و غبار در هفت ایستگاه سینوپتیک استان خوزستان، در بازه زمانی ۵۰ ساله (۱۹۷۰-۲۰۱۹) بود. شاخص‌های نیکویی برازش برای

- 18- Kandy
- 19- Eberhart
- 20- Personal Best
- 21- Global Best
- 22- World Meteorological Organization
- 23- Deep Neural Network
- 24- AutoRegressive Integrated Moving Average
- 25- AutoRegressive
- 26- Moving Average
- 27- Correlation Coefficient
- 28- Root Mean Square Error
- 29- Mean Absolute Error
- 30- Nash-Sutcliffe

- Ahmadi H & Mousavi S F (2018) Comparative study of machine learning algorithms for drought forecasting in arid regions. *Environmental Modelling & Software* 104:1-12 (In Persian)
- Baghbanan P, Ghavidel Y, & Farajzadeh M (2020) Spatial analysis of spring dust storms hazard in Iran. *Theoretical and Applied Climatology* 139(3-4):1447-1457 (In Persian)
- Bahmani S & Najafi F (2017) Hybrid AI models for flood forecasting: Case study of Iran. *Natural Hazards* 87(1):57-71 (In Persian)
- Bakhshizadeh A, Sadeghi K, Ahmadi S, & Royaei J (2023) Damage identification in long-span cable-stayed bridges under multiple support excitations. *International Journal of Civil Engineering* 21(8):1275-1290 (In Persian)
- Borzou F, Zolfaghari H, Masoompour Samakosh J, & Sahraei J (2021) Spatial analysis of dust storms in Iran based on climatic and vegetation characteristics. *Geography and Environmental Sustainability* 11(1):1-23 (In Persian)
- Chafi Z S & Afrakhte H (2021) Short-term load forecasting using neural network and particle swarm optimization (PSO) algorithm. *Wiley Online Library*
- Dargahian F & Pourhashemi M (2022) Detection of climate change based on cold temperature indices in the forest ecosystem of Central Zagros. *Forest Research and Development* 8(2):197-215 (In Persian)
- Dargahian F, Ghasemiaryan Y, & Heydarnejad S (2024) Revealing the change of the frost indices as a consequence of climate change: A case study of Northern Zagros forests (Azerbaijan). *Iranian Journal of Forest and Range Protection Research* 22(1):30-46 (In Persian)
- Ebrahimi H & Mohammadi J (2020) Application of extreme learning machine for rainfall-runoff simulation. *Hydrological Processes* 34(21):3938-3949 (In Persian)
- Ebrahimi-Khusfi Z, Taghizadeh-Mehrjardi R, & Nafarzadegan A R (2021) Accuracy, uncertainty, and interpretability assessments of ANFIS models to predict dust concentration in semi-arid regions. *Environmental Science and Pollution Research* 28(6):6796-6810 (In Persian)
- Hamidi M, Kavianpour M R, & Shao Y (2014) Numerical simulation of dust events in the Middle East. *Aeolian Research* 13:59-70 (In Persian)
- Hamidianpour M, Jahanshahi S M A, Kaskaoutis D G, Rashki A, & Nastos P G (2021) Climatology of the Sistan Levar wind: Atmospheric dynamics driving its onset, duration and withdrawal. *Atmospheric Research* 260:105711 (In Persian)
- Heydarian P, Ashrafi K, Mohebbali M, Kia E B, Aryaeipour M, Sharafi A C, ... & Rokni M B (2017) Seroprevalence of human fasciolosis in Lorestan Province, western Iran, in 2015-16. *Iranian Journal of Parasitology* 12(3):389 (In Persian)
- Mohammed F K, Beckles D M, & Opadeyi J (2018) Characterization, source apportionment, and human health risk assessment of polycyclic aromatic hydrocarbons (PAHs) in road dust of a small island state in the Caribbean. *Human and Ecological Risk Assessment: An International Journal* 24(7):1852-1871
- Omidvar K & Omid Z (2013) The analysis of dust phenomenon in the southern and central Fars province. *The Journal of Geographical Research on Desert Areas* 1(1):85-114 (In Persian)
- Pourgholam-Amiji M, Ansari Ghoghhar M, & Ahmadaali K (2021) Prediction of dust storms in Khuzestan province using artificial neural networks. *Nivar* 45(114-115):56-75 (In Persian)
- Rahmati O, Panahi M, Ghiasi S S, Deo R C, Tiefenbacher J P, Pradhan B, ... & Bui D T (2020) Hybridized neural fuzzy ensembles for dust source modeling and prediction. *Atmospheric Environment* 224:117320 (In Persian)
- Samadi, M, Darvishi Bolorani A, Alavipanah S K, Mohamadi H, & Najafi M S (2014) Global dust detection index (GDDI): A new remotely sensed methodology for dust storms detection. *Journal of Environmental Health Science and Engineering* 12:1-14
- Shahsavani A, Naddafi K, Haghhighifard N J, Mesdaghinia A, Yunesian M, Nabizadeh R, ... & Goudarzi G (2012) The evaluation of PM10, PM2.5, and PM1 concentrations during the Middle Eastern Dust (MED) events in Ahvaz, Iran, from April through September 2010. *Journal of Arid Environments* 77:72-83 (In Persian)
- Sobhani B, Safarian Zengir V, & Faizollahzadeh S (2020) Modeling and prediction of dust in western Iran. *Physical Geography Research* 52(1):17-35 (In Persian)
- Socha J (2008) Effect of topography and geology on the site index of *Picea abies* in the West Carpathian, Poland. *Scandinavian Journal of Forest Research* 23(3):203-213
- Tosan M, Nourani V, Kisi O, & Dastourani M (2025) Evolution of ensemble machine learning approaches in water resources management: A review. *Earth Science Informatics* 18(2):1-36

Tositti L, Brattich E, Cassardo C, Morozzi P, Bracci A, Marinoni A, ... & Zappi A (2022) Development and evolution of an anomalous Asian dust event across Europe in March 2020. *Atmospheric Chemistry and Physics* 22(6):4047–4073

Zhang L & Li Q (2018) Application of support vector machines for flood prediction. *Hydrological Sciences Journal* 63(9):1482-1495